

存算一体技术研究进展及其在电网中的应用探索

焦飞¹, 宋睿¹, 张鋆¹, 彭国政¹, 周华良², 李友军², 赵传奇¹, 张树华¹

(1. 中国电力科学研究院有限公司, 北京市 海淀区 100192;

2. 南瑞集团有限公司, 江苏省 南京市 211100)

Development of Compute-in-memory Technology and Its Potential Implementation in Power Grid

JIAO Fei¹, SONG Rui¹, ZHANG Jun¹, PENG Guozheng¹, ZHOU Hualiang², LI Youjun², ZHAO Chuanqi¹, ZHANG Shuhua¹

(1. China Electric Power Research Institute, Haidian District, Beijing 100192, China;

2. NARI Group Corporation, Nanjing 211100, Jiangsu Province, China)

ABSTRACT: The methods of data-driven artificial intelligence have shown considerable superiority in the practical application of power system operation and maintenance. However, at present, the artificial intelligence technology has not been widely applied in power systems. One of the key reasons is the insufficient ability of power computing equipment for supporting the AI (artificial intelligence) models. On one hand, the limited resources on the power edge and end devices result in the insufficient computing power commonly existing, which makes the deployment and operation of the complex power AI models unpractical. On the other hand, the expansion and increase of the complexity of the power systems, the power cloud computing centers have to process the PB level of mass data and carry out a large scale power dispatching calculations. The computing equipment appears “not being able to calculate”, which makes it difficult to meet the rapid response of the power system and the rising energy consumption. Compute-in-memory technology, a new computing paradigm that directly uses the memory for data processing, can realize the high computing power with low power consumption, providing a new path for solving the problems raised in new power systems. This article summarizes the mainstream researches of compute-in-memory technology in detail, and explains the feasibility of the application of compute-in-memory technology in the power grids. It also puts forward some potential power application scenarios, and analyzes the challenges that may be faced with in the actual application. The aim of this article is to clarify the focus and direction of the application of compute-in-memory technology in the power grids.

KEY WORDS: power system; compute-in-memory technology; high computing power; low power consumption; edge AI

摘要: 基于数据驱动的人工智能方法在电力系统运维实际应用中展示出相当的优势,但目前人工智能技术在电力系统中还未能实现泛在落地应用,其关键原因之一为电力智能计算设备对人工智能模型的支撑能力不足。一方面,目前电力边、端侧设备资源受限,普遍存在计算能力不足等问题,无法支撑复杂电力人工智能模型的部署和运行;另一方面,由于电力系统规模的扩大和复杂程度的增加,电力云计算中心需要处理PB级海量数据并进行大规模电力调度计算,开始出现“算不动”的问题,难以满足电力系统快速响应需求,且耗能也不断攀升。存算一体技术是一种直接利用存储器进行数据处理的新型计算技术,可实现高算力、低功耗电力数据高效能处理,为解决新型电力系统难题提供了新的思路。基于此,详细归纳了存算一体技术的主流研究方向,阐释了存算一体技术在电网应用的可行性,提出了一些潜在电力应用场景,分析了实际应用中可能会面临的挑战,旨在为存算一体技术在电网的应用明确重点和方向。

关键词: 电力系统; 存算一体技术; 高算力; 低功耗; 边缘智能

DOI: 10.13335/j.1000-3673.pst.2022.2241

0 引言

在“碳达峰、碳中和”目标的指引下,电力系统正发生广泛而深刻的变革,建设以新能源为主体的新型电力系统是大势所趋。电力系统运行机理日趋复杂,逐渐从传统的机理驱动转变为机理和数据双轮驱动。作为数据驱动的典型代表,人工智能(artificial intelligence, AI)将在新型电力系统中发挥极其重要作用。然而,目前人工智能技术在电力系统中还未能实现泛在落地应用,其关键原因之一

基金项目: 国家重点研发计划项目(2021YFB2401000)。

Project Supported by National Key R&D Program of China (2021YFB2401000).

是电力智能计算设备对人工智能模型的支撑能力不足。

随着电网的数字化转型,大量传感器和终端设备被投入到电网中,这也使得电网变成了一个越来越庞大的数据源:1)电力用户基数大。据统计,为了更好的服务电力用户,目前已经接入智能电表5.2亿只、终端设备近4600万台,日采集数据量达到650GB,累计采集数据量已达PB级。2)电网覆盖面广,对其运行状况的监测亦会产生大量数据。截至目前,我国输电线路总长已达114.2万km,而对线路电压、电流及输电廊道入侵异物等的监测势必伴随着巨量数据的生成。仅以输电线路监测图像数据为例,依据国网公司发布的输电线路智能监拍设备相关企标,智能监拍设备最小采集时间间隔不应大于1min,即使每1km内只设置一台监拍设备,按照1080p分辨率图像的最小存储大小为6M计算,每月将产生28.23PB的图像数据。正因如此,以云端服务器算力为基础的云处理模式已经开始难以适应电网需求。大规模数据的流动会造成通信链路的严重阻塞,而云计算中心也开始出现“算不动”、“存不下”等现实问题。

不难预计,在未来,对电网数据的处理和应用离不开边缘智能技术。通过将算力下沉到分散的服务器中,边缘智能技术可以有效的分散和缓解数据的传输、计算和存储压力,但“智能”的实现又离不开算力的支撑。而在电网应用边缘智能技术有其特别之处。一般的,为了充分发挥边缘智能技术的优势,需要将边缘智能计算设备设置在数据的源头附近,而在电网中,这常常意味着野外等供电受限区域,使得绝大多数边缘智能计算设备只能依靠太阳能进行供电。以华为最新的Atlas 200 AI加速模块(型号:3000)为例,在5.5W的典型功耗下仅能给出22 TOPS的算力,在太阳能板与电池的支撑下,难以实现高精度实时图像处理模型的稳定运行。如果能够进一步提升边缘智能设备的计算能效,将可以大幅提升人工智能技术在电网应用的实用性,为电网进一步的智能化带来契机。

然而,现有电力智能计算设备均采用传统的冯·诺依曼计算架构,计算能效提升空间有限。这主要是由于存储单元和计算单元分离,存在“功耗墙、存储墙”瓶颈^[1],缩小芯片制程并不能弥补架构的先天不足。“功耗墙”形成的原因是频繁的数据迁移。研究表明,数据迁移功耗与数据计算功耗一般相差多个数量级,例如32位加运算所消耗的能量仅是数据搬运的约1/400;而“存储墙”的形

成则归因于运算器和存储器之间的性能差距和有限的总线带宽^[2]。并且,随着中美对抗的加剧,芯片制备技术成为了“卡脖子”技术,国产硬件算力的发展短时间内甚至难以依靠缩小芯片制程这一传统技术手段来实现。

上述瓶颈及现实因素限制了电力人工智能技术的发展和应用,其具体表现在:一方面,目前人工智能模型需要极高的算力,电力智能计算设备(尤其是边缘侧设备)算力不足阻碍了电力人工智能技术的落地应用,例如电力缺陷实时目标检测、电力智能语音识别、电力知识图谱技术等。另一方面,电力人工智能模型的训练和推理显著增加了电力智能计算设备的功耗,如电力数据和超算中心等,都是“耗能大户”,与“双碳”目标不匹配。

为了突破冯·诺依曼计算架构的瓶颈,斯坦福研究所的Kautz等人于1969年提出了存算一体计算机的概念,但受限于当时的半导体制备能力,“存算一体”直至21世纪才真正被实现并投入应用。存算一体技术是一种直接在存储器中实现计算的新型计算范式,可以突破“功耗墙、存储墙”的瓶颈,为人工智能计算提供高计算能效比(兼具高算力和低功耗特点)。由于其不受芯片制程限制,可以有效缓解国外技术垄断对我国硬件算力发展带来的影响,存算一体技术无疑是当下最佳的自主可控高算力解决方案。近年,国内如莘芯科技、九天睿芯、知存科技等厂家已经实现了存算一体技术的商业化转化,为存算一体技术在未来电网中的应用提供了现实基础。

目前,存算一体技术已可以支持深度神经网络(deep neural networks, DNN)^[1]、循环神经网络(recurrent neural network, RNN)^[3]等主流神经网络结构的高能效比计算,主要被用于为数据中心、互联网、智慧交通、智慧工控和智慧安防等提供高算力支撑,或在超低功耗下实现神经网络(neural network, NN)环境降噪算法、健康监测与分析算法等,以满足物联网终端、手机终端和可穿戴终端的应用需求。存算一体技术在电力领域的应用将能明显提升电力边、端侧智能设备算力,有效降低电力智能云计算中心设备能耗,为电力人工智能技术的实际应用落地提供良好的硬件基础,其在电力领域具备良好的研究和应用前景。

因此,本文详细综述了存算一体技术的主流研究方向,分析了存算一体技术在电网中的应用前景,并对其发展提出了一些展望及思考,希望能为存算一体技术在电网的实际应用提供一些思路和启发。

1 存算一体技术

1.1 存算一体技术基本原理

存算一体是一种利用新材料、新器件和新型计算架构突破“存储墙”和“功耗墙”的技术。其直接利用存储器进行数据处理，消除了运算过程中因数据搬运带来的功耗和时延，特别适用于电力人工智能这种计算量大、计算方式繁复的应用场景。

目前主流的神经网络多基于卷积算子实现，在诸如电力缺陷图像识别等应用中，95%以上的运算为向量矩阵乘法(multiply accumulate, MAC)^[1]。存算一体计算架构与向量矩阵乘法兼容性好，支持乘加运算在存储器本地完成，能够有效省去数据搬运过程，明显加速其中的乘运算与加运算、大幅削减功耗。

存算一体计算架构主要分为大容量逐位计算架构(bulk bitwise computing)和交叉矩阵计算架构(crossbar array computing)^[4]，见图1。前者主要用于实现基于易失性器件的存内计算，包括动态随机存储器(dynamic random access memory, DRAM)^[5-8]、静态随机存储(static random access memory, SRAM)^[2,3,9-15]等。而随着金属氧化物阻性随机存储器(resistive random access memory, ReRAM)^[16-21]、快闪存储器(flash memory, Flash)^[22-26]、磁性随机存储器(magnetic random access memory, MRAM)^[27-33]、铁电晶体管(ferroelectric field effect transistor, FeFET)^[34-35]等非易失性器件的出现和发展，基于这类器件的阻性宏观表征，衍生出了交叉矩阵计算架构。

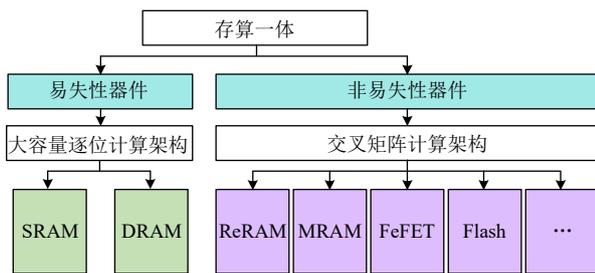


图1 存算一体技术架构

Fig. 1 Compute-in-memory architectures

目前，基于 DRAM、SRAM 和 Flash 的存算一体已逐步走向商业化，具备较高的可靠性。而有能力代工 ReRAM、MRAM、FeFET 存算一体芯片的厂家较为有限，所以基于这类器件的存算一体暂时难以实现技术的工业化、规模化和低成本化转变。值得一提的是，在国家科技部发布的科技创新2030—“新一代人工智能”重大项目2021年度项目申报指南中，已将“基于 ReRAM 存算一体计算单元及其硅基工艺实现”列入研究内容。相信在不

久的将来，基于 ReRAM、MRAM 和 FeFET 等器件的存算一体技术，将更多地走入人们的视野。

1.1.1 大容量逐位计算架构

目前，大容量逐位计算架构是主流的存算一体实现架构，如图2所示。以逐位进行逻辑操作的方式，实现存储器中信息的本地运算。通过将操作数和运算后的输出设置在同一位线上(列)，再同时激活多个写入线(行)上的存储单元，利用读出放大器直接实现位线上的逻辑运算操作。由于存储器内大量位线的计算操作都是并列进行的，存储器本身就构成了一个大容量并行计算引擎。以文献[8]为例，该研究相关团队利用22nm制程实现了每个分阵列(subarray)2048个并行计算位线的DRAM存算一体，可并行进行数以十万计的逻辑操作。

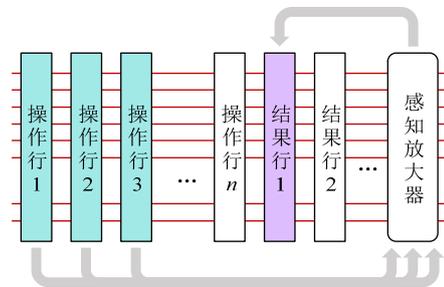


图2 大容量逐位计算架构

Fig. 2 Bulk bitwise computing architecture

1.1.2 交叉矩阵计算架构

得益于非易失性存储技术的发展，交叉矩阵计算架构开始走入人们的视线。利用非易失性器件的宏观阻性表征，将矩阵乘加运算直接等效为输入电压与器件导纳乘积电流线性叠加的过程，如图3所示。需要提到的是，为了方便解释说明，本文将这些宏观阻性表征的易失性器件定义为阻性器件，用电阻符号做统一指代。由于推理计算过程本身无需时钟协调控制、无需数据搬运，为纯物理过程，可以大幅加快运算速度、降低计算功耗。

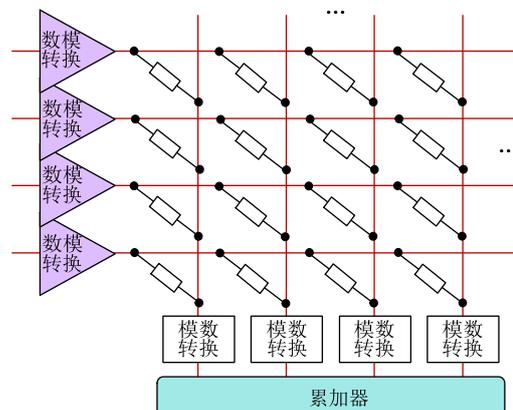


图3 交叉矩阵计算架构

Fig. 3 Crossbar array computing architecture

目前，交叉矩阵计算架构也已能够实现各类神经网络的推理运算加速，并且在器件允许的情况下能更好的支持多值神经网络的复杂加乘，得出更准确的推理运算结果。同时，其完全改变了加乘运算在计算机体系中的实现方法，无需逻辑门的参与，这也进一步提升了运算速度、简化了逻辑过程。相比大容量逐位计算架构，交叉矩阵计算架构将实现的难点从复杂逻辑控制转移到了新型器件制备，是未来深度神经网络推理加速的重要研究方向。

1.2 几种适应电网需求的存算一体技术

存算一体 AI 加速单元的系统集成方法如图 4 所示。存算一体单元既是计算单元，也是存储单元，所以在应用时可作为片/板上协处理器或片/板上存储使用，可替代图形处理器(graphics processing unit, GPU)等传统 AI 加速单元或普通存储器件。其并非中央处理器(central processing unit, CPU)的替代器件，因此与传统的冯·诺依曼架构芯片有着较好的兼容性，受 CPU 或其他主控单元调用，仅用于加速 AI 推理等繁复运算过程。值得注意的是，各种存算一体技术之间没有绝对的优劣，其最佳应用生态应该是多种存算一体技术的阶梯化、层次化结合。例如具有计算优势的 SRAM 存算一体模块适宜被用作高速缓存，具备功耗优势的 ReRAM、MRAM 存算一体模块适合被用作嵌入式内存，而具备存储优势的 Flash、DRAM 存算一体模块更适合被用作主存，在相互协调和配合运作中，有层次的实现数据的存储和就地运算。

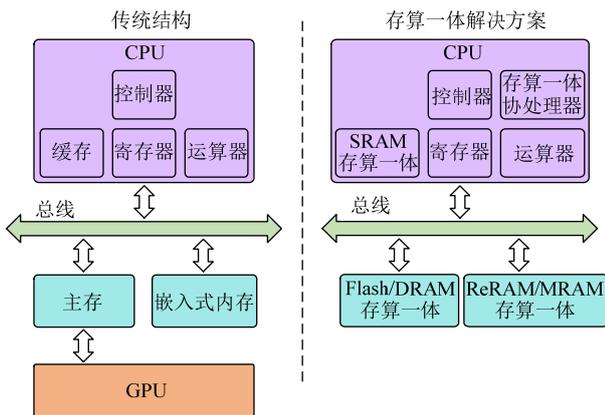


图 4 存算一体 AI 加速单元的系统集成方法
Fig. 4 Implementation of compute-in-memory modules

在实际应用中，各类电力计算终端除了要进行 AI 推理运算，还需要进行大量的普通运算(非 AI 运算)。从前面的论述中不难发现，受益于其计算机理，存算一体器件可以有效加快乘加运算、免去繁复数据搬运所带来的功耗，但在进行非常简单的运算时，优势并不明显，因而对其的调用原则应与

GPU 一致：在进行简单运算时，CPU 性能足以覆盖需求，无需调用存算一体加速器件；而在进行包含大量乘加运算的计算行为时，则可将需要计算的数据发送到存算一体器件，待其完成计算后直接读取结果并返回 CPU 进行后续的处理。进一步的，对于涉及复杂公式和重复迭代的普通(非 AI)运算过程，可以面向存算一体计算架构，利用普遍性定理，进行非 AI 运算过程的神经网络化转化，应用神经网络拟合逼近需要计算的公式，即可进行任意公式的乘加化转化，从而更充分地将存算一体器件利用起来。

综合考虑制备工艺的成熟度、存储器件的可靠性、芯片计算的能效比以及主流的研究现状，本节根据电力系统的不同应用需求，对基于 SRAM、ReRAM 和 Flash 器件的存算一体技术进行深入讨论。

1.2.1 适应电力高算力应用的 SRAM 存算一体技术

作为易失性器件和非阻性器件，SRAM 主要依托大容量逐位计算架构对神经网络运算过程实现加速。SRAM 实现存内计算的一种基本方法如图 5 所示。利用读出放大器甄别同一位线上被串联的多个存储单元输出，就可以分别实现“与”逻辑和“或非”逻辑。为了减少运算过程篡改存储数据的可能性，需要降低读数电压，但这不可避免的会影响读取速度。具代表性的 SRAM 存算一体加速器如 Neural Cache^[9]、IMAC^[10]、XNOR-SRAM^[11-12]等，都是依据类似的原理实现操作数在存储单元上的直接运算的。通过在读出放大器上附加锁存器，Neural Cache 已经可以完成大数据位串行相加、相减、相乘、比较、搜索和复制等操作。IMAC 巧妙利用逐次逼近模数转换原理，成功实现了多值加速卷积计算。XNOR-SRAM 利用 8 管 SRAM 单元实现了 XNOR 运算对二值/三值卷积运算的替代。其他的 SRAM 存算一体实现方法还有基于时域计算(time-domain computation)的 SRAM 存算一体等，利用压控振荡器或边缘延迟单元(edge delay cell)，将同一位线上多个 SRAM 连通后得到的电压转变为脉冲宽度或延时，再利用时间-数字转换器完成读数^[13]。

基于 SRAM 的存算一体目前已有商业化案例，应用覆盖数据中心、互联网、智慧交通、智慧工控、智慧安防、智慧健康等行业和领域，可以灵活支持各类主流神经网络，且相关技术完全自主可控，非常符合电网需求。除了上文中提到的无人机电路巡检、智慧电力调度和智慧电力交易等应用场景，SRAM 存算一体的算力优势和灵活性优势还适合

支撑电力边缘侧应用，例如基于边缘智能的电力缺陷识别和输电线路防外破等。

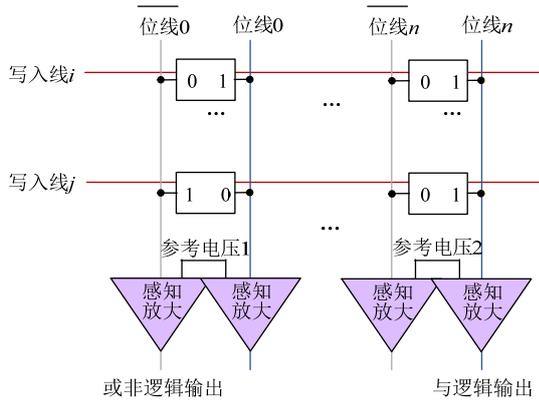


图5 基于SRAM的存算一体技术原理

Fig. 5 Principle of SRAM based compute-in-memory

1.2.2 适应电力低功耗应用的ReRAM存算一体技术

ReRAM 藉由对自身电阻值的控制实现对权重等信息的存储，支持多值存储。具有代表性的ReRAM工作原理见图6,通过给金属氧化物两侧的电极施加不同的电压信号或脉冲信号，就可以控制ReRAM 在高阻态和低阻态之间切换，实现存储信息的改变。正是基于这一原理和交叉矩阵计算架构，文献[17]有效实现了神经网络的加速运算。另外，通过修改ReRAM的微架构，还进一步实现了sigmoid、ReLU(rectified linear units)、最大池化、数模/模数转换等功能和函数。ISAAC^[18](in-situ analog arithmetic in crossbars)直接实现了模拟输入电压和模拟电阻值的矩阵乘加运算。Pipelayer^[19]引入了分批层内模型并行(batch level intra-layer parallelism)的概念，使得数据写入和计算得以并行完成。Atomlayer^[20]使用大容量DRAM 主存来存储训练和推理的初值和中间值，有针对性的解决了 ISAAC 神经网络的训练问题和 Pipelayer 的功耗问题。

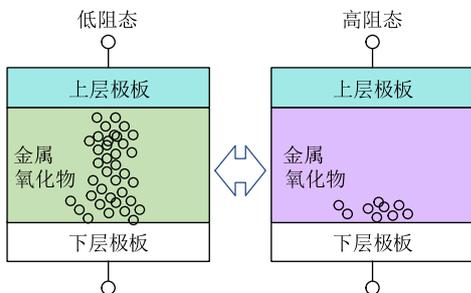


图6 基于ReRAM的存算一体技术原理

Fig. 6 Principle of ReRAM based compute-in-memory

受益于交叉矩阵架构计算原理与特性，基于ReRAM 的存算一体加速器可以最大限度的减小功耗。在最新研究中，基于ReRAM 的存算一体边缘智能加速芯片已经可以在二进制到8位精度计算中

实现 1286.4 TOPS/W 到 21.6 TOPS/W 的能效比^[21]。其能耗优势可以很好的支撑电力传感器和电力能效终端(电表)的智能化。一方面，电力智能传感器可以在 ReRAM 存算一体技术的支持下实现数据的就地前处理和预推理。另一方面，ReRAM 存算一体可被用于升级智能能效终端(智能电表)，使其具备解决时空序列预测问题的能力，在用户侧实现个性化的用能策略定制。

1.2.3 适应电力大存储应用的Flash存算一体技术

Flash 存储器利用隧穿效应将电荷存储在浮栅中，从而实现对信息的存储。当浮栅中的电荷量足够大时，就可以使源极和漏极间呈现低阻态，否则源、漏极之间不导通。除了提供高、低阻态外，还可以利用浮栅内存储的电荷实现阻值的模拟调整，其工作原理类似于三极管在变阻区内运行的原理^[22]。基于Flash 的存算一体技术原理如图7所示。最新的研究成果例如浙江大学团队的Flash 存算一体加速器^[23]、旺宏电子股份有限公司(Macronix International Co., Ltd.)的存算一体加速器^[24]等，均基于交叉矩阵计算架构兼容二值和多值神经网络的加速。由于Flash 技术支持在CMOS 芯片上的3-D堆叠，可以在不增加芯片尺寸的情况下实现更复杂的深度神经网络计算操作^[25]；目前，已经有研究团队证明这种3-D结构可以直接通过标准CMOS工艺来实现^[26]。

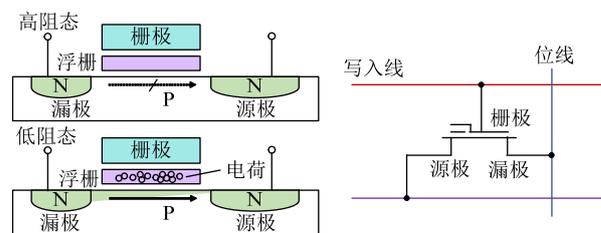


图7 基于Flash的存算一体技术原理

Fig. 7 Principle of Flash based compute-in-memory

用作普通存储器时，Flash 与 DRAM 的存储单元构成相对简单，与其他存储技术相比拥有明显的存储空间优势。而比起需要频繁刷新的 DRAM，Flash 又具备明显的功耗优势。所以基于Flash 的存算一体技术非常适合支撑对存储空间和算力都有一定要求的应用，例如在电力大数据挖掘、快速潮流计算和智慧电力交易等场景中，基于Flash 的存算一体技术均具备更广阔的实用前景。

1.3 存算一体技术驱动的运算能效比提升

存算一体计算架构带来的能效提升主要得益于其大幅减少甚至完全避免了人工智能推理运算中繁复的数据搬运过程。在传统冯·诺依曼计算机

体系结构中,运算操作都需要经过将数据从存储器取出到处理器中进行计算,再存回存储器的过程。一方面,这使得传统冯·诺依曼计算机对存储器过度依赖,处理器访问存储器的速度反向制约了整个系统运行的速度。尤其近年来存储器性能的发展严重滞后,产生了所谓的“储存墙瓶颈”。另一方面,处理器本身设有“功耗墙”,主要是为了控制其在工作时产生的温度,保证其性能、延长其寿命。实际上,繁复的数据搬运过程中引动的充放电电流才是温升的最主要原因,而只有控制了温度才能进一步发挥处理器及存储器的性能。

在存算一体计算结构当中,计算过程几乎都在存储器本地通过一些简单逻辑电路实现,避免了数据在存储器和处理器间的往复传递,既节省了完成计算操作所需的时钟数量,又减少了信号在传输线路上的频繁翻转,使得计算能效比大幅上升。例如台积电应用 7nm 互补金属氧化物半导体(complementary metal oxide semiconductor, CMOS)技术研制的 SRAM 存算一体芯片已经实现对乘均运算 351 TOPS/W 的能效参数,约是华为最新锐人工智能处理器“昇腾 310”的 10^2 倍^[14]。诸如文献[15-16]中提到的存算一体加速器也显著提高了卷积神经网络(convolutional neural network, CNN)推理运算的能效比,超出传统人工智能加速器逾 10 倍以上。

虽然存算一体技术在电力领域还未得到实际应用,但其在智能可穿戴、物联网、数据中心、互联网、智慧交通、智慧工控和智慧安防等领域已有所建树,展现了强大的技术活力。由阿里巴巴达摩院发布的“2023 年十大科技趋势”一文就指出,存算一体芯片将在垂直细分领域迎来规模化商用。目前,例如知存科技的 WTM2101、九天睿芯的 ADA100 等存算一体芯片已经落地智能手表、无线耳机等可穿戴品类及照明、开关、遥控器物联网终端。相较于嵌入式神经网络处理器(neural-network processing unit, NPU)、数字信号处理(digital signal processing, DSP)芯片、微控制单元(microcontroller unit, MCU)等计算平台,存算一体芯片将 AI 算力提高了 10~200 倍,在利用深度学习网络进行推理运算时仅消耗 $50\mu\text{A}\sim 3\text{mA}$,加速了可穿戴设备及物联网终端的智能化进程。在数据中心、互联网等领域,目前 AI 部署主要依靠 GPU。市面上计算能效比最高的 GPU 是由英伟达(NVIDIA)在 2022 年推出的 Hopper H100 AI GPU,所能提供的计算能效比 <100 GFLOPS/W。而由灵汐科技推出的面向服务器的存算一体类脑计算加速卡 HP300,可提供 >650 GFLOPS/W

的计算能效比。这也意味着在相同的 AI 算力下,以存算一体加速卡为核心的服务器或计算中心相较以 GPU 为核心服务器或计算中心,可节省约 85% 的电能消耗,优势明显,将大幅降低 AI 部署成本。

未来,将存算一体技术引入电网,使其在电力应用场景中发挥作用,将能有效支撑人工智能技术在电网的落地应用,为电网带来助益。一方面,通过大幅降低电力边缘侧和电力端侧设备的功耗,可以促进人工智能算法在这些环节上的有效部署。另一方面,存算一体技术的应用可以显著提升电力超算中心/电力云计算中心的性能,进一步保证运算结果的实时性和实效性。本文梳理了电力人工智能技术在电网建设和运维中起到的一些作用,归纳了电力人工智能技术在部署及应用中涉及到的一些问题并提出了相应的存算一体解决方案,希望对广大读者有所启发。

2 存算一体技术在电力边、端侧应用的探索

随着电网数字化建设不断深入,电力传感器、用户终端等端侧设备产生了海量多模态数据,这为基于数据驱动的人工智能提供了良好基础,但同时也带来了一些问题,如对数据上下行链路和存储空间造成了极大负担,导致处理时延增加。因此,仅依托云端智能,难以满足新型电力系统实际需求。

实现边侧和端侧的智能化,可以极大缓解云端“存不下、大时延”问题。但是边、端侧智能在电力场景应用受限于能效比瓶颈,如输电线路场景的边、端侧设备主要依靠太阳能板及储能电池供电,难以支撑推理运算所需要的算力,尤其在恶劣天气条件下,电池性能的下降和光照条件的恶化极易导致设备宕机。边、端侧智能落地问题成为学术界和工业界研究的热点。从软件层面,目前已经有学者尝试应用各种模型压缩方法(剪枝、量化、知识蒸馏)对电力人工智能模型进行精简,以期减小其对硬件性能的要求,但是这种方法不可避免的会造成识别精度的下降,推理运算能效比的提升幅度也较为有限^[36-39]。从硬件层面,目前华为、瑞芯微、寒武纪、英伟达等均推出了用于提升边、端侧计算能效比的芯片、模组、板卡,但由于其针对性不强,在电力行业未能规模应用。

相比之下,存算一体处理核心具备超高计算能效比,可以有效提升边、端侧设备在恶劣天气条件下的续航能力,在输电线路可视化监拍、无人机巡检、输配电关键设备状态感知等方面均有广泛的应用前景。

2.1 电力边缘智能终端应用

目前，电力边缘智能终端等边缘智能设备已经在电网进行试点投运。其具备计算、存储和通信功能，上可无缝连接电力数据中心及云计算中心，下可有效管理接入的通信设备、感知设备、量测设备和执行设备。其主要功能定位在于：通过各类通信手段收集量测数据并开展本地的数据处理和分析决策^[40]。

和绝大多数边缘侧设备一样，电力边缘智能终端也面临算力与功耗的矛盾。尤其随着电网的扩展和多元化升级，需要处理的数据越来越多，需要完成的任务也越来越繁杂，如输电线路外破图像识别、导地线及金具异常状态检测、变电站人员安全

监测、配电柜传感融合异常监测、跳线电气间隙判别、配电设备故障分析^[41]等业务，均要求推理结果的准确性和实时性。而受限于太阳能板等取能器件的供电能力，现有电力边缘侧设备无法为这些业务提供足够的算力支持，雨雪冰冻等极端天气条件对电池性能的影响更是会影响其正常运行。以输电线路异物目标检测为例，如果应用目前市面上主流的边缘智能加速器“华为 atlas200”模块，若要满足目标检测模型运行需求和低检测时延需要，电力边缘设备功耗将难以被控制在 5W 以下，为设备供电带来困难。输电线路边缘智能终端异常目标检测架构见图 8。

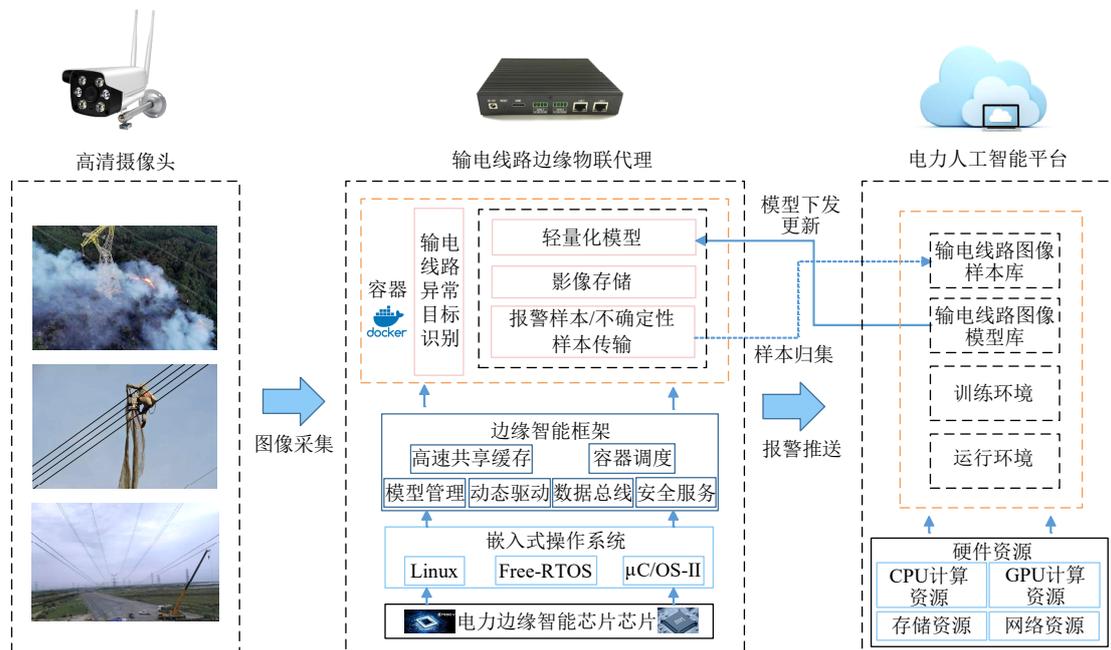


图 8 输电线路边缘智能终端异常目标检测架构

Fig. 8 Architecture of transmission line abnormal target monitoring based on an edge device for power IoT

正如文献[42]所述，边缘智能的诞生与硬件算力的提升密不可分，而硬件算力的进一步升级必然对未来边缘智能的应用和发展起到关键作用。一方面，为电力应用定制的存算一体智能加速核心就是电力边缘技术落地的推手。电力智能缺陷识别^[36-39]等技术的实现目前主要依靠深度学习网络，推理过程主要由乘加运算组成。存算一体技术的引入将能显著降低这些推理计算的功耗，有效提升人工智能技术在电力边缘应用场景中的时效性、实用性。另一方面，存算一体技术所带来的算力提升能促进电力边缘智能技术的进一步发展。例如变压器故障诊断技术，一直以来都是行业研究的热点。目前，对于变压器故障的诊断主要基于单一判据，如油中溶解气体信号，分类模型复杂度相对较低，主要面向故障的本地快速诊断和及时响应需求^[43]。通过应用

基于存算一体技术的高算力边缘智能设备，可以支撑多模态数据融合及计算密集型模型的部署，进一步引入振动、声音、温度、特高频局部放电、铁芯或夹件接地电流、红外热成像、文本数据等参量作为诊断依据，实现更精准多样的故障研判。文献[44]对比了目前在电力场景中实际应用的边缘智能芯片的性能(包括英伟达、华为、瑞芯微、赛灵思等主流厂家推出的芯片)，其中表现最佳的为华为 Ascend 310 芯片，能效比为 2.75 TOPs/W，尚不足以支撑上述电力边缘智能应用。而由九天睿芯推出的基于 SRAM 存算一体技术的 ADA20X 边缘侧 AI 芯片已经可以提供 20 TOPs/W 的高能效比，这意味着在电池性能相同的情况下，其可为边缘智能终端提供约 8 倍的算力或延长约 7 倍的续航时间，可显著增强智能终端对电力边缘智能应用的支撑能力。

需要说明的是,除了进行 AI 推理运算任务外,边缘智能设备有时还需应用非 AI 手段对各类电力传感器上传的数据进行简单处理(例如协议解析、逻辑判断),此时可直接应用其内嵌的 CPU/MCU/DSP 来完成,通过任务协同获取最优的性能。

2.2 电力无人机巡检应用

传统的输电设施运维主要依靠人工巡检的方式进行,但人工巡检不仅工作负担重,时常还伴有一定风险,人力成本与作业成本居高不下。巡检无人机的发展与普及则为电力巡检行业带来了全新变革。利用无人机巡检不仅可以将巡视效率提升 6~10 倍、大幅缩短巡视周期,还可以进行带电作业,避免停电对用户产生影响。应用无人机巡线,不仅可以对输电线路本体缺陷、通道隐患进行快速检测,还能在各种复杂地形、恶劣气候、灾害天气下,及时、准确、高效地获取现场信息,是载人巡检飞机的有力替代品^[45]。但目前电力无人机的实际应用还存在一些突出问题和不足。第一,部分电力单位内外交互传输带宽小,无人机单张图片传输时间甚至超过 10s,严重影响缺陷识别实时性;第二,部分电力单位对适航区的规划标准不清晰,无人机没有越界告警和紧急返回功能,飞巡安全管控能力不足。

为了解决这些问题,除了要对算法进行升级,更要化解边缘侧计算能效差和应用需求高的根本矛盾。针对图片上传识别延迟大的问题,有学者已经提出利用改进 Faster Region-CNN^[46]、改进 DCNN (deep CNN)^[47]、改进 MobileNet-SSD^[48](single shot detector)等轻量化网络实现目标本地检测的方法,但典型功耗甚至达到 20W^[48],会对电力无人机巡航时间产生不利影响。而无人机自主路线规划、自主避障等功能^[49-52],也可以通过神经网络予以实现,但都不可避免的会明显增加处理功耗,对机载计算资源提出挑战。

在电力无人机上应用存算一体神经网络加速技术,一方面可以在保证续航的情况下支撑深度学习模型运行,实现无人机的实时故障诊断、实时避障、拍摄角度调整与巡检区域规划。另一方面可以利用存算一体处理器提升无人机基站算力,实现图像的低功耗边缘侧预处理/处理,大幅缓解数据传输压力。目前,已有多家存算一体芯片供应商实现机载式视觉加速模块的研制,支持无人机设备的快速灵活性能升级,可通过网口或 USB 接口直接为无人机提供算力加持,在低功耗下实现本地图像识别等功能。未来,通过软硬件协同开发和优化将更充分挖掘存算一体技术在无人机实时姿态控制、灵活

路线规划和无人机集群工作等方面的应用潜力,有效增强无人机的自主性和可靠性。

2.3 电力智能传感器应用

电力单点感知数据的价值低,聚合后价值高^[53],目前电力数据的智能化应用主要依靠数据向边云上行。一方面,这造成了通信链路的阻塞,另一方面,通信是传感器功耗的主要组成部分,直接决定了传感器寿命。事实上,电网运行过程和监测系统产生的大多数数据价值较低,并具有时效性。如果能实现传感器端侧的超低功耗数据预处理甚至结果预推理,就能在保证其寿命的情况下,有效筛选出有用的数据或直接导出推理结果,大幅减少数据上传量和上传频度。低功耗传感网络如图 9 所示^[53]。

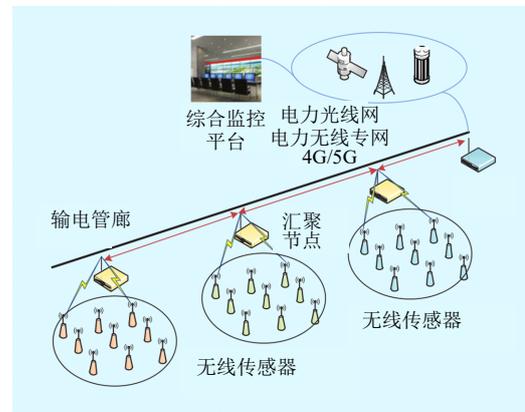


图9 低功耗传感网络

Fig. 9 Low-power sensor network

目前常用的数据处理方法有卡尔曼滤波、小波变换、傅里叶变换等,由于这些方法具有较高的计算复杂度,与传感器受限资源相矛盾,无法在传感器上运行。存算一体技术可以通过查表^[54]等方式实现快速的数据处理,大幅缩减处理功耗和硬件资源消耗,提升传感器数据本地处理的可行性。如九天睿芯的 ADA 100,就是一种为传感器定制的低成本、超低功耗(nW 级)处理器芯片,等效算力可达 1Gops。除了利用存算一体技术支撑小波变换、傅里叶变换等数据预处理过程,还可以将神经推理网络的一部分订制为存算一体芯片,植入传感器中,进行对传感器一段时间内测量数据的预推理,而只上传推理结果,从而大幅缩减传感器通信需求,释放通信资源,提升传感器寿命。如知存科技研发的 WTM2001 存算一体芯片,就可以在微瓦级功耗下,运行各类神经网络(neural network, NN)分析算法,实现传感器数据的本地预处理,为传感器智能的实现提供了硬件基础和新的思路。

2.4 电力智能电表应用

精细化用电需求预测对电网的稳定运行和用

用户体验的提升有着非常重要的作用。为了实现对用户需求的精准预测，需要持续不断收集用户用电量、用电时间等数据。目前，在大城市，智能电表基本普及，每天不间断的采集小区住户、写字楼租户、商场商户等用户的用电情况数据。随着智能电表数量的进一步增加，用电情况数据量也爆发式增长。如果将所有数据都上传至云端进行处理，不仅会造成云端运算、存储负担过重，还会造成通讯链路阻塞等问题。实际上，用户的用电需求具备特异性、专一性，统一处理需求弱，适合采用分布式处理和推理的方式，进行面向特定用户的用电行为预测。所以，如果能提升智能电表算力，不仅将有效缓解通信压力和云端计算存储压力，还能实现用户的定制化用能、供能策略生成。

用电量预测主要包括以计划为目的的长、中期用电需求预测和以调控为目的的短期用电需求预测。短期用电需求预测是实现中长期预测的基础，目前主要依靠人工智能手段来实现，例如应用长短期记忆网络(long short-term memory, LSTM)^[55-56]等进行负荷预测模型的构建。LSTM 中包含时间记忆单元，适用于处理和预测时间序列中的间隔和延迟事件，对用户短期用能需求有很好的预测效果。

构成 LSTM 网络的算子比较简单，以矩阵、向量运算为主，与存算一体技术兼容性强。所以，将存算一体技术引入智能电表将为其提供足以支撑分布式用能预测的高算力，在释放云端资源和通信资源的同时规避通信延时等弊端，在提供定制化用

能预测的同时有效提高预测实时性，提升用户体验、促进节能减排。

3 存算一体技术在电力云端侧应用的探索

在本文中，电力云端应用主要指的是依托电力超算中心/电力云计算中心实现的电力人工智能应用场景。电力超算中心是电力系统的大脑，具备在线仿真、故障分析、优化控制等核心功能，为保证电力系统安全稳定运行提供了有力保障。目前，电力数据中心需要处理PB级海量数据和大规模电力调度计算^[57]，功耗极大，甚至被称为“不冒烟的工厂”。

而存算一体技术就有能力为超算中心的功耗问题提供高效的解决方案。据现有运行数据证实，通过在服务器中应用存算一体计算芯片，将可实现运行功耗的成倍降低，例如前文中提到过的服务器类脑 AI 加速卡 HP 300，相较目前能效比最高的 GPU，在提供相同算力时可节省约 85% 的电能消耗。其同时还具有计算性能强、计算并行度高、泛化能力好的特点，能满足高精度仿真计算、多模态大数据分析和深度学习训练与推理等需求，为大电网实时运行和在线分析提供加速引擎。高算力、低碳化的电力超算中心未来将在源-网-荷-储自主调控、新能源精准预测、大电网实时仿真、智慧电力交易和故障在线分析等方发挥重要作用。电力低碳化云端计算如图 10 所示。图 10 中，CCUS 表示碳捕集、利用与封存(carbon capture, utilization and storage)。

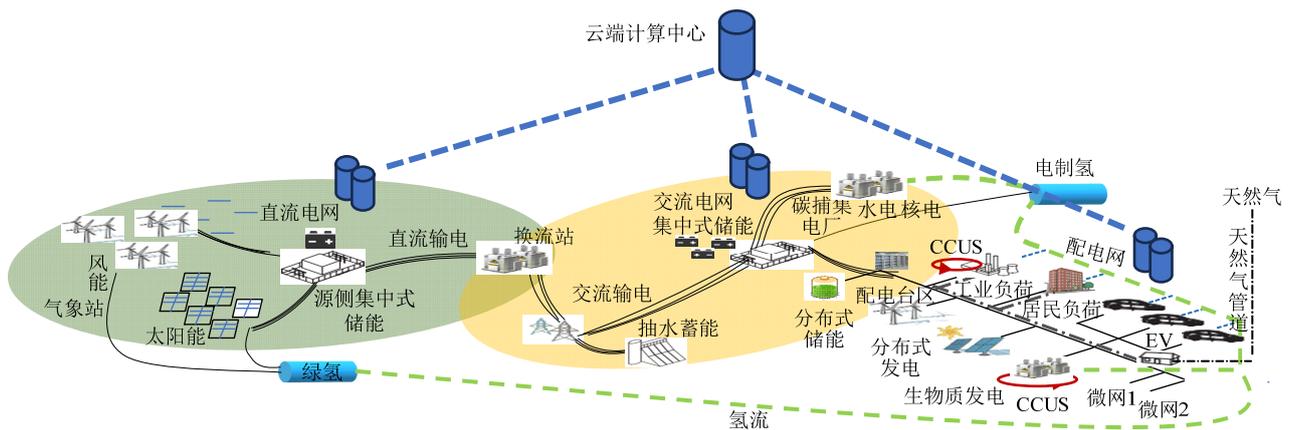


图 10 电力低碳化云端计算

Fig. 10 Low-carbon-emission cloud center for power grid

3.1 快速潮流计算应用

2003 年，意大利电网在多个元件相继断开后发生大停电^[58]，是近年来影响最为深远的停电事故之一^[59-60]。为了避免类似停电事故的发生，我国于 2019 年更新了电力系统安全稳定导则，在静态安全分析“N-1 准则”的基础上增补了“N-2 准则”^[61]。

而随着电网的不断发展和新能源设施的大量接入，“N-2”场景数呈爆炸式增长。而传统的交流潮流算法需迭代求解，难以满足实际工程中在线潮流计算的需求^[62]。为此，有学者提出利用人工智能技术进行安全评估分类^[63-64]和快速潮流计算^[62,65-66]，在保证结果准确性的情况下大幅提升了评估和计算

的速度,但对于节点数量多的系统,仍需进一步优化。例如文献[62]中所提到的基于卷积神经网络(convolutional neural network, CNN)的快速潮流计算方法,虽然能将 IEEE 188 节点系统潮流计算时间控制在 0.5s 以内,但在节点数增加的情况下可能难以满足在线分析需求。

值得注意的是,这些先进的计算方法主要依靠支持向量机、人工神经网络、前馈神经网络、卷积神经网络等,均与存算一体技术有较高兼容性。使用电力专用存算一体服务器进行实时潮流计算将能大幅加速评估过程,同时将明显减少计算功耗,为日趋复杂电网的安全稳定运行保驾护航。

3.2 调度策略优化应用

电力系统需要有序调配电功率的输送,稳定平衡电力供给和负载需求。随着电力系统的日趋复杂化,尤其随着新能源技术的广泛应用,调度策略的制定和优化也变得越来越重要,是保证电网安全、稳定、可靠、经济运行的关键手段。调度策略的优化技术一直是电网相关研究的热点,近年来,随着人工智能技术的引入,源-网-荷-储预测的精度有所提升,调度优化技术的实用性也得到了长足的发展^[67-78]。目前源-网-荷-储预测多以 LSTM 等神经网络为基础,例如有学者提出的基于离散小波变换(discrete wavelet transform, DWT)、CNN 和 LSTM 的超短期光伏发电功率预测方法^[74],基于麻雀搜索算法(sparrow search algorithm, SSA)和 LSTM 的海上风电功率预测方法^[75]和基于 CNN 和 LSTM 的短期负荷预测方法^[76]等。与 2.4 节中所提到的智能电表应用不同, LSTM 在源-网-荷-储预测中的应用往往涉及更多的参量,尤其对于风能和太阳能的预测还可能需要引入风速^[77]和气象数据^[78]等异构元素,所以对算力要求更高。当源-网-荷-储规模、数量大时,很可能会引发云计算中心“算不动”的问题,且随着新能源电源的不断加入和电网复杂程度的日益增加,计算时延也会不断攀升,明显影响调度策略的实时性。

为了解决这一问题,除了兴建电力超算中心外,还可以借助存算一体技术来实现电力源-网-荷-储实时预测和调度策略快速生成。虽然构成 LSTM 的算子比较简单,但高维 LSTM 的参数数量巨大,数据搬运会造成明显延时。以 8 个输入、8 个权重、4 个偏置的 1024 维 LSTM 层为例,其参数大小是 16MB。假设用 80GB/s 带宽的双倍速率同步动态随机存储器(double data rate synchronous dynamic random access memory, DDR SDRAM)作为存储,

仅加载一层权重就需要 0.2ms 左右,不难想象整个 LSTM 网络的计算延时。而存算一体技术正是参数量-存储带宽矛盾的一个潜在解决方案。例如基于 Flash 的存算一体加速器就可以同时满足 LSTM 的存储需求和快速计算需求,并且能大幅降低数据搬运所造成的功耗。

值得注意的是,除了在电力云计算中心实现集中式的源-网-荷-储预测外,还可以利用分布式的存算一体边缘计算设备在源、网、荷、储实现就地预测,并只上传预测结果,从而进一步缓解数据上下行压力。

3.3 智慧电力交易应用

在未来以新能源为主体的电网中,电力市场及电力交易对促进可再生能源消纳及实现节能减排的目标具有重要意义。狭义的电力市场指的是电力现货市场和电力中长期交易,而电力用户负荷曲线的预测在这之中起着至关重要的作用^[79]。本文已经对电力负荷预测作了一定程度的探讨,此处就不再赘述。在电力市场决策优化中,除了负荷预测外,还需要根据电力市场和网架结构、供需关系等,对电力市场中的实时价格和日前价格进行预测^[80-84]。例如有学者提出的基于 SSA、LSTM 和纵横交叉算法(crisscross optimization, CSO)的含高比例新能源电力市场日前电价预测方法,将电价、负荷和风光发电量作为日前电价预测模型的输入特征,有效提高了预测精度^[80]。再例如基于最大信息系数相关性分析和改进多层级门控 LSTM 的短期电价预测方法,同样选取了电价、负荷等作为模型输入完成预测^[81]。进一步的,在“电碳并重”发展目标的指引下,碳监测、碳计量、碳交易等碳业务将与电监测、电计量、电交易等电业务深度耦合,越来越多的维度和参数将被纳入电力交易的范畴。

不难看出,在输入参数(序列)增多的情况下,对于 LSTM 类模型的计算延时将无法避免的增长,这会明显影响计算的实时性,导致交易收益受限或下降。所以,在电价预测领域,更需要存算一体技术的支撑来实现预测速度的提升和计算功耗的控制。在得到电价预测结果后就可以结合负荷预测结果导出市场主体优化决策。另一方面,在输入参数序列较大的情况下, LSTM 模型的训练时长也将大幅增加。这是由于需捕获的序列间依赖关系跨度将会变长,基于梯度下降的参数优化计算会变得更加困难。但理论上,在短期电价的预测中,更多的相关参数序列通常意味着更好的预测效果^[81]。如有需要,未来可以采用专门设计的存算一体训练加速芯

片,将神经网络反向传播过程也纳入加速范围,实现更优电价预测模型的训练和优化。

3.4 电力材料筛选应用

随着电力系统复杂程度的升级,电网对新材料、新器件提出了越来越高的要求。尤其在建设以新能源为主体的新型电力系统的过程中,高性能储能材料、高可靠性绝缘材料和以绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)为代表的电力开关器件都起着举足轻重的作用。以绝缘材料为例,截至2020年,我国从事绝缘材料经营的公司多达10万家,国内电力绝缘材料年消耗高达147万t,居世界第一。但氧化锌等绝缘避雷材料仍难以满足高端应用需求。一方面,电压梯度、残压、老化等性能不够理想,大幅增加了特高压避雷器及被保护设备的体积、技术制造难度及成本。另一方面,通流容量、参数一致性等性能不够理想,在超特高压直流系统吸能装置等新应用场景,ABB等国际厂商产品也常发生故障。

目前,对电力IGBT半导体材料、高性能锂电池储能材料、高可靠性绝缘材料、高效率光伏材料的筛选主要依靠人工实验,筛选效率低、周期长、成本高。近年来,基于机器学习和密度泛函计算的新型材料筛选方法提供了高效的解决思路^[85-86]。但是,由于分子动力学方程复杂度极高,计算耗时极长,未能实际投入大规模应用。例如,基于第一性原理分子动力学计算数百个原子、1ns的物理过程,即使用数千个CPU核的超级计算机,也需要计算1个月以上。为了解决这一问题,文献[87]向分子动力学计算领域引入了存算一体技术,通过使用基于存算一体加速技术的新型AI算法,实现了多个数量级的密度泛函计算加速,精准预测了材料分子运动特性,大幅提升了密度泛函材料筛选方式的实用性。未来,可以将存算一体技术和分子动力学计算原理应用到电力领域中,大幅提升电力新型材料的制备和优化速度,为新型电力系统的建设提供高性能材料支撑。

4 存算一体技术在电网应用中面临的挑战与展望

4.1 存算一体技术在电网应用中面临的挑战

虽然存算一体技术在电网的应用具备可观潜力和广阔空间,其最终的实际落地还要克服一些困难和挑战。作为一种新兴技术,想要在电网得到实际应用,首先必须保证其可靠性。目前还缺乏对于存算一体技术的电力可靠性验证,需要全面评估存

算一体芯片在特殊工作环境(如复杂电磁环境等)中和特殊工况(如高、低温工况等)下的工作能力。尤其对于基于ReRAM等新器件的存算一体芯片,需要保证其在极端温度条件下的稳定性,才能满足各类电力部署场景的要求和需求。

其次,存算一体技术与人工智能模型耦合程度较高,为了最大程度发挥存算一体芯片的性能,通常需要向硬件厂商开放模型代码,无法满足电力人工智能模型隐私性和安全性要求。因此需要开发电力专用的存算一体芯片编译平台,支持多厂商的存算一体硬件架构高层次抽象,具备电力模型向存算一体芯片的精准映射能力,实现电力模型端到端部署。

最后,需要建立完整的电力产业生态和应用生态。这需要电力科研院所、电力智能计算设备厂家、电网企业协同研发、切实推广,实现性能与电力场景的最终融合。另一方面,需要进一步深挖现有电力技术难以解决的电网技术难题,结合人工智能等新兴技术手段,为存算一体技术开辟新的应用场景,创造传统芯片无法覆盖的存算一体电力应用领域和应用市场。

4.2 结论与展望

1) 存算一体计算架构是一种直接利用存储器进行数据处理的新型类脑计算架构。与传统冯·诺依曼计算架构相比,其免去了繁复的数据搬运,故而具备高算力、低功耗等特点和优势。目前能更好适应电网应用场景的存算一体技术主要有基于SRAM、ReRAM和Flash的存算一体技术。

2) 存算一体技术在电力边、端的应用主要解决了算力与功耗的矛盾,为处于复杂环境、有供电和通信限制的边、端侧设备提供了就地实现智能化的手段,为人工智能技术在边缘侧的部署提供了算力基础和能效比保证。

3) 存算一体技术在电力云端的应用主要解决了“算不动、大时延”的问题,促进了计算密集型电力人工智能技术的实际应用,在缩减计算功耗的同时有效提高了智能推理计算结果的实时性、实效性。

下一步,电力存算一体技术将聚焦在边缘侧融合电力边缘计算、微机器学习等技术,提升电力系统分布式就地计算和自主运行能力;在云端侧需融合人工智能、数字孪生等技术,支撑电网实时态势感知和调度策略快速生成。

新型电力系统具有“范围更广、环节更多、实时性更强、随机性更高、服务更多元”的新特征。要打造精准反映、状态及时、全域计算、协同联动

的数字技术支撑体系, 计算算力基础设施是关键要素。存算一体技术的“高算力、低功耗”特性与新型电力系统的基础设施建设需求相吻合, 可以为云、边、端全域电力智能计算设备提供算力支撑, 能在电网运行维护、碳管理、绿电交易、数字增值服务等业务中提高数据推演的实时性, 进一步激发数据活力。未来, 新型电力系统的新需求将有效促进上下游产业的发展, 有力推动电力存算一体技术的研究和应用。

参考文献

- [1] 郭昕婕, 王绍迪. 端侧智能存算一体芯片概述[J]. 微纳电子与智能制造, 2019, 1(2): 72-82.
GUO Xinjie, WANG Shaodi. Overview of edge intelligent computing-in-memory chips[J]. Micro/Nano Electronics and Intelligent Manufacturing, 2019, 1(2): 72-82(in Chinese).
- [2] WANG Jingcheng, WANG Xiaowei, ECKERT C, et al. A 28-nm compute SRAM with bit-serial logic/arithmetic operations for programmable in-memory vector computing[J]. IEEE Journal of Solid-State Circuits, 2020, 55(1): 76-86.
- [3] GUO Ruiqi, LIU Yonggang, ZHENG Shixuan, et al. A 5.1pJ/Neuron 127.3us/Inference RNN-based speech recognition processor using 16 computing-in-memory SRAM macros in 65nm CMOS[C]//Proceedings of 2019 Symposium on VLSI Circuits. Kyoto: IEEE, 2019.
- [4] BAVIKADI S, SUTRADHAR P R, KHASAWNEH K N, et al. A review of in-memory computing architectures for machine learning applications[C]//Proceedings of 2020 on Great Lakes Symposium on VLSI. ACM, 2020.
- [5] SESHADRI V, LEE D, MULLINS T, et al. Ambit: in-memory accelerator for bulk bitwise operations using commodity DRAM technology[C]//Proceedings of 50th Annual IEEE/ACM International Symposium on Microarchitecture. Boston: IEEE, 2017.
- [6] LI Shuangchen, NIU Dimin, MALLADI K T, et al. DRISA: a DRAM-based reconfigurable in-situ accelerator[C]//Proceedings of the 50th Annual IEEE/ACM International Symposium on Microarchitecture. Boston: IEEE, 2017.
- [7] DENG Quan, JIANG Lei, ZHANG Youtao, et al. DrAcc: a DRAM based accelerator for accurate CNN inference[C]//Proceedings of the 55th ACM/ESDA/IEEE Design Automation Conference. San Francisco: IEEE, 2018.
- [8] LI Shuangcheng, GLOVA A O, HU Xing, et al. SCOPE: a stochastic computing engine for DRAM-based in-situ accelerator[C]//Proceedings of the 51st Annual IEEE/ACM International Symposium on Microarchitecture. Fukuoka: IEEE, 2018.
- [9] ECKERT C, WANG Xiaowei, WANG Jingcheng, et al. Neural cache: bit-serial in-cache acceleration of deep neural networks[J]. IEEE Micro, 2019, 39(3): 11-19.
- [10] ALI M, JAISWAL A, KODGE S, et al. IMAC: in-memory multi-bit multiplication and accumulation in 6T SRAM array [J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2020, 67(8): 2521-2531.
- [11] YIN Shihui, JIANG Zhewei, SEO J S, et al. XNOR-SRAM: in-memory computing SRAM macro for binary/ternary deep neural networks[J]. IEEE Journal of Solid-State Circuits, 2020, 55(6): 1733-1743.
- [12] JIANG Zhewei, YIN Shihui, SEO J S, et al. XNOR-SRAM: in-bit cell computing SRAM macro based on resistive computing mechanism[C]//Proceedings of the 2019 on Great Lakes Symposium on VLSI. Tysons Corner: ACM, 2019: 417-422.
- [13] YANG Jun, KONG Yuyao, WANG Zhen, et al. 24.4 Sandwich-RAM: an energy-efficient in-memory BWN architecture with pulse-width modulation[C]//Proceedings of 2019 IEEE International Solid-State Circuits Conference. San Francisco: IEEE, 2019.
- [14] DONG Qing, SINANGIL M E, ERBAGCI B, et al. 15.3 A 351TOPS/W and 372.4GOPS compute-in-memory SRAM macro in 7nm FINFET CMOS for machine-learning applications[C]//Proceedings of 2020 IEEE International Solid-State Circuits Conference. San Francisco: IEEE, 2020.
- [15] YUE Jinshan, YUAN Zhe, FENG Xiaoyu, et al. 14.3 A 65nm computing-in-memory-based CNN processor with 2.9-to-35.8TOPS/W system energy efficiency using dynamic-sparsity performance-scaling architecture and energy-efficient inter/intra-macro data reuse [C]//Proceedings of 2020 IEEE International Solid-State Circuits Conference. San Francisco: IEEE, 2020.
- [16] XUE Chengxin, HUANG T Y, LIU J S, et al. 15.4 A 22nm 2Mb ReRAM compute-in-memory macro with 121-28TOPS/W for multibit MAC computing for tiny AI edge devices[C]//Proceedings of 2020 IEEE International Solid-State Circuits Conference. San Francisco: IEEE, 2020.
- [17] CHI Ping, LI Shuangchen, XU Cong, et al. PRIME: a novel processing-in-memory architecture for neural network computation in ReRAM-based main memory[C]//Proceedings of 2016 ACM/IEEE 43rd Annual International Symposium on Computer Architecture. Seoul: IEEE, 2016: 27-39.
- [18] SHAFIEE A, NAG A, MURALIMANOHAR N, et al. ISAAC: a convolutional neural network accelerator with in-situ analog arithmetic in crossbars[C]//Proceedings of the ACM/IEEE 43rd Annual International Symposium on Computer Architecture. Seoul: IEEE, 2016.
- [19] SONG Linghao, QIAN Xuehai, LI Hai, et al. PipeLayer: a pipelined ReRAM-based accelerator for deep learning[C]//Proceedings of 2017 IEEE International Symposium on High Performance Computer Architecture. Austin: IEEE, 2017.
- [20] QIAO Ximing, CAO Xiong, YANG Huanrui, et al. AtomLayer: a universal ReRAM-based CNN accelerator with atomic layer computation[C]//Proceedings of the 55th ACM/ESDA/IEEE Design Automation. San Francisco: IEEE, 2018.
- [21] HUNG J M, HUANG Y H, HUANG S P, et al. An 8-Mb DC-current-free binary-to-8b precision ReRAM nonvolatile computing-in-memory macro using time-space-readout with 1286.4- 21.6TOPS/W for edge-AI devices[C]//Proceedings of 2022 IEEE International Solid-State Circuits Conference. San Francisco: IEEE, 2022: 1-3.
- [22] 丁士鹏, 黄鲁. 基于 NOR Flash 的存算一体模拟乘加电路设计[J]. 信息技术与网络安全, 2021, 40(6): 69-74.
DING Shipeng, HUANG Lu. Design of an analog multiply accumulate circuit based on NOR Flash[J]. Cyber Security and Data Governance, 2021, 40(6): 69-74(in Chinese).
- [23] ZHAO Liang, GAO Shifan, ZHANG Shengbo, et al. Neural network acceleration and voice recognition with a Flash-based in-memory computing SoC[C]//Proceedings of 2021 IEEE 3rd International Conference on Artificial Intelligence Circuits and Systems. Washington: IEEE, 2021.
- [24] HSU T H, LUE H T, HSU P K, et al. A vertical split-gate Flash memory featuring high-speed source-side injection programming, read disturb free, and 100k endurance for embedded Flash (eFlash)

- scaling and computing-in-memory (CIM)[C]//Proceedings of 2020 IEEE International Electron Devices Meeting. San Francisco: IEEE, 2020: 6.3.1-6.3.4.
- [25] LUE H T, WANG K C, LU C Y. Introduction of 3D AND-type Flash memory and it's applications to computing-in-memory (CIM)[C]//Proceedings of 2021 International Symposium on VLSI Technology, Systems and Applications. Hsinchu, China: IEEE, 2021: 1-2.
- [26] KIM M, LIU Muqing, EVERSON L R, et al. An embedded NAND flash-based compute-in-memory array demonstrated in a standard logic process[J]. IEEE Journal of Solid-State Circuits, 2022, 57(2): 625-638.
- [27] 高鹏, 郑之明, 邢定钰. 隧道磁电阻效应中的两种不同的理论方法[J]. 物理学报, 2002, 51(9): 2128-2132.
GAO Peng, ZHENG Zhiming, XING Dingyu. Two different approaches in the magnetic tunneling junctions[J]. Acta Physica Sinica, 2002, 51(9): 2128-2132(in Chinese).
- [28] PAN Yu, OUYANG Peng, ZHAO Yinglin, et al. A multilevel cell STT-MRAM-based computing in-memory accelerator for binary convolutional neural network[J]. IEEE Transactions on Magnetics, 2018, 54(11): 1-5.
- [29] ANGIZI S, HE Zhezhi, AWAD A, et al. MRIMA: an MRAM-based in-memory accelerator[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2020, 39(5): 1123-1136.
- [30] PATIL A D, HUA Haocheng, GONUGONDLA S, et al. An MRAM-based deep in-memory architecture for deep neural networks [C]//Proceedings of 2019 IEEE International Symposium on Circuits and Systems. Sapporo: IEEE, 2019.
- [31] FAN Deliang, ANGIZI S. Energy efficient in-memory binary deep neural network accelerator with dual-mode SOT-MRAM[C]//Proceedings of 2017 IEEE International Conference on Computer Design. Boston: IEEE, 2017: 609-612.
- [32] ANGIZI S, HE Zhezhi, PARVEEN F, et al. IMCE: energy-efficient bit-wise in-memory convolution engine for deep neural network[C]//Proceedings of the 23rd Asia and South Pacific Design Automation Conference. Jeju: IEEE, 2018.
- [33] ANGIZI S, HE Zhezhi, RAKIN A S, et al. CMP-PIM: an energy-efficient comparator-based processing-in-memory neural network accelerator[C]//Proceedings of 55th ACM/ESDA/IEEE Design Automation Conference. San Francisco: IEEE, 2018.
- [34] YIN Guodong, CAI Yi, WU Juejian, et al. Enabling lower-power charge-domain nonvolatile in-memory computing with ferroelectric FETs[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2021, 68(7): 2262-2266.
- [35] LONG Yun, KIM D, LEE E, et al. A ferroelectric FET-based processing-in-memory architecture for DNN acceleration[J]. IEEE Journal on Exploratory Solid-State Computational Devices and Circuits, 2019, 5(2): 113-122.
- [36] ZHANG Jun, WANG Jiye, ZHANG Shuhua. An ultra-lightweight and ultra-fast abnormal target identification network for transmission line[J]. IEEE Sensors Journal, 2021, 21(20): 23325-23334.
- [37] YANG Lei, FAN Junfeng, LIU Yanhong, et al. A review on state-of-the-art power line inspection techniques[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(12): 9350-9365.
- [38] TAO Xian, ZHANG Dapeng, WANG Zihao, et al. Detection of power line insulator defects using aerial images analyzed with convolutional neural networks[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2020, 50(4): 1486-1498.
- [39] WANG Bo, MA Fuqi, GE Leijiao, et al. Icing-EdgeNet: a pruning lightweight edge intelligent method of discriminative driving channel for ice thickness of transmission lines[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 2501412.
- [40] 马凯, 欧晓勇, 雷卫, 等. 边缘物联代理装置设计及在电缆沟道综合监测的应用[J]. 电力信息与通信技术, 2020, 18(11): 56-62.
MA Kai, OU Xiaoyong, LEI Wei, et al. Design of IoT edge agent device and its application on integrated monitoring for cable channel [J]. Electric Power Information and Communication Technology, 2020, 18(11): 56-62(in Chinese).
- [41] 樊轶, 周俊, 刘遐龄, 等. 基于 GOOSE 协议和边缘计算的配电网设备监测系统[J]. 电力信息与通信技术, 2021, 19(12): 61-68.
FAN Yi, ZHOU Jun, LIU Xialing, et al. Distribution network equipment monitoring system based on GOOSE and edge computing [J]. Electric Power Information and Communication Technology, 2021, 19(12): 61-68(in Chinese).
- [42] WANG Xiaofei, HAN Yiwen, LEUNG V C M, et al. Edge AI: convergence of edge computing and artificial intelligence[M]. Singapore: Springer, 2020.
- [43] 朱庆东, 朱文兵, 王浩哲, 等. 基于油中溶解气监测的变压器在线半监督故障诊断方法研究[J]. 电网技术, 2023, 47(3): 1031-1037.
ZHU Qingdong, ZHU Wenbing, WANG Haozhe, et al. Online semi-supervised fault diagnosis of transformer based on dissolved gas in oil [J]. Power System Technology, 2023, 47(3): 1031-1037(in Chinese).
- [44] 周胤宇, 王波, 朱丹蕾, 等. 基于 AI 芯片的电力边缘智能终端: 结构框架及其应用场景[J]. 电力信息与通信技术, 2021, 19(9): 77-85.
ZHOU Yinyu, WANG Bo, ZHU Danlei, et al. Power edge intelligent terminal based on AI chip: structural framework and application scenarios[J]. Electric Power Information and Communication Technology, 2021, 19(9): 77-85(in Chinese).
- [45] 叶方舟, 刘晓冬, 李良, 等. 无人机在输变电设备巡检巡视中的应用[J]. 河北电力技术, 2019, 38(4): 20-22.
YE Fangzhou, LIU Xiaodong, LI Liang, et al. Application of unmanned aerial vehicle patrol inspection for power transmission and distribution equipment[J]. Hebei Electric Power, 2019, 38(4): 20-22(in Chinese).
- [46] 宋建辉, 王思宇, 刘砚菊, 等. 基于改进 FFRCNN 网络的无人机地面小目标检测算法[J]. 电光与控制, 2022, 29(7): 69-73, 80.
SONG Jianhui, WANG Siyu, LIU Yanju, et al. Ground small target detection algorithm of UAV based on improved FFRCNN network [J]. Electronics Optics & Control, 2022, 29(7): 69-73, 80(in Chinese).
- [47] 戴永东, 姚建光, 李勇, 等. 基于定点化自适应选择卷积神经网络的电力缺陷识别方法[J]. 高电压技术, 2021, 47(11): 3827-3835.
DAI Yongdong, YAO Jianguang, LI Yong, et al. Power defect recognition method based on fixed-point adaptive selection convolution neural network[J]. High Voltage Engineering, 2021, 47(11): 3827-3835(in Chinese).
- [48] 崔令飞, 郭永红, 修全发, 等. 基于国产嵌入式智能计算平台的无人机检测方法[J]. 兵工学报, 2022, 43(S1): 146-154.
CUI Lingfei, GUO Yonghong, XIU Quanfa, et al. UAV detection method based on domestic embedded intelligent computing platform [J]. Acta Armamentarii, 2022, 43(S1): 146-154(in Chinese).
- [49] 成怡, 郑腾龙. 深度学习的无人机双目视觉避障研究[J]. 电光与控制, 2021, 28(10): 31-35.
CHENG Yi, ZHENG Tenglong. Binocular visual obstacle avoidance of UAV based on deep learning[J]. Electronics Optics & Control, 2021, 28(10): 31-35(in Chinese).
- [50] 张香竹, 张立家, 宋逸凡, 等. 基于深度学习的无人机单目视觉避障算法[J]. 华南理工大学学报(自然科学版), 2022, 50(1): 101-108, 131.
ZHANG Xiangzhu, ZHANG Lijia, SONG Yifan, et al. Obstacle avoidance algorithm for unmanned aerial vehicle vision based on deep

- learning[J]. Journal of South China University of Technology (Natural Science Edition), 2022, 50(1): 101-108, 131(in Chinese).
- [51] 吕智梁, 梁晓龙, 任宝祥, 等. 基于模糊神经网络的无人机实时避障算法[J]. 空军工程大学学报(自然科学版), 2021, 22(5): 82-89. LYU Zhihu, LIANG Xiaolong, REN Baoxiang, et al. A real-time barrier avoidance algorithm for UAV based on fuzzy neural networks[J]. Journal of Air Force Engineering University(Natural Science Edition), 2021, 22(5): 82-89(in Chinese).
- [52] 王延祥, 王宏伦, 吴健发, 等. 基于流体扰动算法与深度神经网络的无人机自适应路径规划[J]. 无人系统技术, 2020, 3(6): 50-58. WANG Yanxiang, WANG Honglun, WU Jianfa, et al. Adaptive path planning for UAV based on interfered fluid algorithm and deep neural network[J]. Unmanned Systems Technology, 2020, 3(6): 50-58(in Chinese).
- [53] 郭经红, 梁云, 陈川, 等. 电力智能传感技术挑战及应用展望[J]. 电力信息与通信技术, 2020, 18(4): 15-24. GUO Jinghong, LIANG Yun, CHEN Chuan, et al. Challenge and application prospect of power intelligent sensor technology[J]. Electric Power Information and Communication Technology, 2020, 18(4): 15-24(in Chinese).
- [54] 阿西木·约麦尔, 陈小刚, 陆俊杰, 等. 基于相变存储查找表的低功耗存算一体计算方案[J]. 功能材料与器件学报, 2021, 27(6): 519-524. YUEMAIER A, CHEN Xiaogang, LU Junjie, et al. A low power in-memory computing scheme based on lookup table with PCM[J]. Journal of Functional Materials and Devices, 2021, 27(6): 519-524(in Chinese).
- [55] 周游, 徐丹, 赵灿, 等. 基于 LSTM 的智能家庭用电预测模型研究[J]. 软件工程, 2022, 25(2): 39-41, 38. ZHOU You, XU Dan, ZHAO Can, et al. Research on smart power consumption prediction model of smart home based on LSTM[J]. Software Engineer, 2022, 25(2): 39-41, 38(in Chinese).
- [56] 陈亮, 王震, 王刚. 深度学习框架下 LSTM 网络在短期电力负荷预测中的应用[J]. 电力信息与通信技术, 2017, 15(5): 8-11. CHEN Liang, WANG Zhen, WANG Gang. Application of LSTM networks in short-term power load forecasting under the deep learning framework[J]. Electric Power Information and Communication Technology, 2017, 15(5): 8-11(in Chinese).
- [57] 谢清玉, 张耀坤, 李经纬. 面向智能电网的电力大数据关键技术应用[J]. 电网与清洁能源, 2021, 37(12): 39-46. XIE Qingyu, ZHANG Yaokun, LI Jingwei. Application of key technologies of power big data in smart grids[J]. Power System and Clean Energy, 2021, 37(12): 39-46(in Chinese).
- [58] LIU Yun, XUE Yusheng. Cascading outage analyses by integrating distribution factor method with AC power flow[J]. IEEE Access, 2019, 7: 180887-180897.
- [59] 印永华, 郭剑波, 赵建军, 等. 美加“8. 14”大停电事故初步分析及应吸取的教训[J]. 电网技术, 2003, 27(10): 8-11, 16. YIN Yonghua, GUO Jianbo, ZHAO Jianjun, et al. Preliminary analysis of large-scale blackout in interconnected north America power grid on august 14 and lessons to be drawn[J]. Power System Technology, 2003, 27(10): 8-11, 16(in Chinese).
- [60] 黄道珊. 电网薄弱环节分类识别技术研究[J]. 电力工程技术, 2017, 6(4): 91-97. HUANG Daoshan. Classification and identification of power grid weak links[J]. Electric Power Engineering Technology, 2017, 36(4): 91-97(in Chinese).
- [61] 国家市场监督管理总局, 国家标准化管理委员会. 电力系统安全稳定导则: GB 38755—2019[S]. 北京: 中国标准出版社, 2019.
- [62] 刘学华, 孔霄迪. 基于卷积神经网络的 $N-2$ 线路开断潮流快速计算[J]. 电力工程技术, 2021, 40(4): 95-100. LIU Xuehua, KONG Xiaodi. Fast load flow calculation of $N-2$ contingency based on convolutional neural network[J]. Jiangsu Electrical Engineering, 2021, 40(4): 95-100(in Chinese).
- [63] 朱志慧, 李雷, 种冬梅. 改进的 BT-SVM 应用于电力系统 SSA[J]. 计算机技术与发展, 2012, 22(9): 157-160, 165. ZHU Zhihui, LI Lei, ZHONG Dongmei. Improved binary tree support vector machine and its application to power system static security assessment[J]. Computer Technology and Development, 2012, 22(9): 157-160, 165(in Chinese).
- [64] SAEH I S, MUSTAFA M W, MOHAMMED Y S, et al. Static Security classification and Evaluation classifier design in electric power grid with presence of PV power plants using C-4.5[J]. Renewable and Sustainable Energy Reviews, 2016, 56: 283-290.
- [65] PAUCAR V L, RIDER M J. Artificial neural networks for solving the power flow problem in electric power systems[J]. Electric Power Systems Research, 2002, 62(2): 139-144.
- [66] KARAMI A, MOHAMMADI M S. Radial basis function neural network for power system load-flow[J]. International Journal of Electrical Power & Energy Systems, 2008, 30(1): 60-66.
- [67] 高敏, 鲁怀伟, 乔焱, 等. 计及孤岛微电网不确定性的储能容量优化[J]. 控制工程, 2020, 27(2): 361-367. GAO Min, LU Huaiwei, QIAO Yao, et al. Energy storage capacity optimization considering the uncertainty of islanding micro grid[J]. Control Engineering of China, 2020, 27(2): 361-367(in Chinese).
- [68] WANG Jinsong, CHEN Xuhui, ZHANG Fan, et al. Building load forecasting using deep neural network with efficient feature fusion [J]. Journal of Modern Power Systems and Clean Energy, 2021, 9(1): 160-169.
- [69] 彭嘉宁. 基于人工智能算法的电力系统无功优化调度研究[J]. 机械与电子, 2020, 38(12): 55-59. PENG Jianing. Research on reactive power optimal dispatch of power system based on artificial intelligence algorithm [J]. Machinery & Electronics, 2020, 38(12): 55-59(in Chinese).
- [70] WANG Jinsong, ZHANG Fan, LIU Huanan, et al. Interruptible load scheduling model based on an improved chicken swarm optimization algorithm[J]. CSEE Journal of Power and Energy Systems, 2021, 7(2): 232-240.
- [71] 吴小刚, 许士锦, 陈兴望, 等. 基于知识图谱的电网智能调度辅助决策系统设计[J]. 信息技术, 2021, 45(12): 60-65. WU Xiaogang, XU Shijin, CHEN Xingwang, et al. Design of power grid intelligent dispatching assistant decision system based on knowledge graph[J]. Information Technology, 2021, 45(12): 60-65(in Chinese).
- [72] ZHANG Shuhua, WANG Jinsong, LIU Haibo, et al. Prediction of energy photovoltaic power generation based on artificial intelligence algorithm[J]. Neural Computing and Applications, 2021, 33(3): 821-835.
- [73] 潘志刚, 刘三明, 李莹, 等. 基于深度学习网络的风电场功率短期预测研究[J]. 科技与创新, 2015(19): 4-6. PAN Zhigang, LIU Sanming, LI Ying, et al. Research on the short-term forecasting of wind power based on deep learning network [J]. Science and Technology & Innovation, 2015(19): 4-6(in Chinese).
- [74] 刘旭丽, 莫毓昌, 吴哲, 等. 基于 DWT-CNN-LSTM 的超短期光伏发电功率预测[J]. 郑州大学学报(理学版), 2022, 54(4): 86-94. LIU Xuli, MO Yuchang, WU Zhe, et al. Super-short-term photovoltaic power forecasting based on DWT-CNN- LSTM[J]. Journal of Zhengzhou University (Natural Science Edition), 2022, 54(4): 86-94(in Chinese).

- [75] 李森文, 张伟, 李纯宇, 等. 基于 SSA-LSTM 的海上风电功率预测[J]. 机械与电子, 2022, 40(6): 22-25, 30.
LI Senwen, ZHANG Wei, LI Chunyu, et al. Power prediction of offshore wind farm based on SSA-LSTM[J]. Machinery & Electronics, 2022, 40(6): 22-25, 30(in Chinese).
- [76] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法 [J]. 电力系统自动化, 2019, 43(8): 131-137.
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8): 131-137(in Chinese).
- [77] 袁咪咪, 官法明, 李昕. 基于 CNN-LSTM 的多因素时空风速预测 [J]. 计算机系统应用, 2021, 30(8): 133-141.
YUAN Mimi, GONG Faming, LI Xin. Multifactor spatio-temporal wind speed prediction based on CNN-LSTM[J]. Computer Systems & Applications, 2021, 30(8): 133-141(in Chinese).
- [78] 林艳彬. 基于异构数据融合的超短期太阳能预测[D]. 厦门: 厦门大学, 2019.
- [79] 王清, 李琮琮, 刘松, 等. 基于电力市场交易规则的最优用能策略研究[J]. 电网与清洁能源, 2021, 37(10): 1-7.
WANG Qing, LI Zongzong, LIU Song, et al. Research on optimal energy consumption strategy based on transaction rules of electricity market[J]. Power System and Clean Energy, 2021, 37(10): 1-7(in Chinese).
- [80] 殷豪, 丁伟锋, 陈顺, 等. 基于长短时记忆网络-纵横交叉算法的含高比例新能源电力市场日前电价预测[J]. 电网技术, 2022, 46(2): 472-480.
YIN Hao, DING Weifeng, CHEN Shun, et al. Day-ahead electricity price forecasting of electricity market with high proportion of new energy based on LSTM-CSO model[J]. Power System Technology, 2022, 46(2): 472-480(in Chinese).
- [81] 赵雅雪, 王旭, 蒋传文, 等. 基于最大信息系数相关性分析和改进多层级门控 LSTM 的短期电价预测方法[J]. 中国电机工程学报, 2021, 41(1): 135-146.
ZHAO Yaxue, WANG Xu, JIANG Chuanwen, et al. A Novel short-term electricity price forecasting method based on correlation analysis with the maximal information coefficient and modified multi-hierarchy gated LSTM[J]. Proceedings of the CSEE, 2021, 41(1): 135-146(in Chinese).
- [82] 江婷, 王旭, 蒋传文, 等. 数据驱动下风电-抽蓄联合参与日前-实时市场随机鲁棒竞价策略[J]. 电网技术, 2022, 46(2): 481-491.
JIANG Ting, WANG Xu, JIANG Chuanwen, et al. Optimal hybrid stochastic robust bidding strategy of wind and hydraulic pumped storage jointly participating in day-ahead and real-time market using data-driven method[J]. Power System Technology, 2022, 46(2): 481-491(in Chinese).
- [83] 姚子麟, 张亮, 邹斌, 等. 含高比例风电的电力市场电价预测[J]. 电力系统自动化, 2020, 44(12): 49-55.
YAO Zilin, ZHANG Liang, ZOU Bin, et al. Electricity price prediction for electricity market with high proportion of wind power [J]. Automation of Electric Power Systems, 2020, 44(12): 49-55(in Chinese).
- [84] 李懿鑫, 李正烁, 刘聪聪. 考虑光伏与电价不确定性的综合能源生产单元自调度报价策略研究[J]. 电网技术, 2023, 47(7): 2713-2722.
LI Yixin, LI Zhengshuo, LIU Congcong. Self-scheduling offering strategy of integrated energy production unit considering uncertainty of photovoltaic and electricity prices[J]. Power System Technology, 2023, 47(7): 2713-2722(in Chinese).
- [85] SUN Wenbo, ZHENG Yujie, YANG Ke, et al. Machine learning-assisted molecular design and efficiency prediction for high-performance organic photovoltaic materials[J]. Science Advances, 2019, 5(11): eaay4275.
- [86] FENG Hongjian, WU Kan, DENG Zunyi. Predicting inorganic photovoltaic materials with efficiencies >26% via structure-relevant machine learning and density functional calculations [J]. Cell Reports Physical Science, 2020, 1(10): 100236.
- [87] SHI Mengchao, MO Pinghui, LIU Jie. Deep neural network for accurate and efficient atomistic modeling of phase change memory [J]. IEEE Electron Device Letters, 2020, 41(3): 365-368.



焦飞

在线出版日期: 2023-04-18。

收稿日期: 2022-11-11。

作者简介:

焦飞(1982), 男, 硕士, 高级工程师, 研究方向为电力人工智能、电网设备状态监测、电力传感技术等, E-mail: jiaofei@epri.sgcc.com.cn;

宋睿(1991), 男, 博士, 高级工程师, 研究方向为电力边缘智能技术, E-mail: songrui@epri.sgcc.com.cn;

张鋆(1991), 男, 通信作者, 博士研究生, 研究方向为电力边缘智能技术, E-mail: zhangjun8@hnu.edu.cn。

(责任编辑 郝敬乾 王金芝)