

数据驱动太阳能预测使近优经济决策成为可能

Zhixiang Dai^{1,+,*}, Minghao Yin^{2,3+}, Xuanhong Chen^{4,+,*}, Alberto Carpentieri¹, Jussi Leinonen¹, Boris Bonev¹, Chengzhe Zhong^{2,3}, Thorsten Kurth¹, Jingan Sun¹, Ram Cherukuri¹, Yuzhou Zhang¹, Ruihua Zhang¹, Farah Hariri¹, Xiaodong Ding^{5,3}, Chuanxiang Zhu⁴, Dake Zhang⁶, Yaodan Cui², Yuxi Lu², Yue Song², Bin He², Jie Chen², Yixin Zhu^{7,8}, Chenheng Xu⁸, Maofeng Liu⁹, Zeyi Niu^{10,11}, Wanpeng Qi¹², Xu Shan¹³, Siyuan Xian¹⁴, Ning Lin^{14,15}, and Kairui Feng^{2,3,*}

¹NVIDIA Corporation, Santa Clara, CA, USA

²State Key Laboratory of Autonomous Intelligent Unmanned Systems, Tongji University, Shanghai, China

³Shanghai Innovation Institution, Shanghai, China

⁴School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai, China

⁵University of Shanghai for Science and Technology, Shanghai, China

⁶Antai College of Economics and Management, Shanghai Jiao Tong University, Shanghai, China

⁷School of Psychological and Cognitive Sciences, Peking University

⁸Institute for Artificial Intelligence, Peking University

⁹Department of Atmospheric and Oceanic Sciences, School of Physics, Peking University

¹⁰Shanghai Typhoon Institute, Shanghai, China

¹¹Key Laboratory of Numerical Modeling for Tropical Cyclone of the China Meteorological Administration, Shanghai, China

¹²Qinghai Meteorological Bureau, Qinghai, China

¹³Max Planck Institute for Biogeochemistry, Jena, Germany

¹⁴Department of Civil and Environmental Engineering, Princeton University, Princeton, USA

¹⁵Andlinger Center for Energy and the Environment, Princeton University, Princeton, USA

*Corresponding authors: Zhixiang Dai (zhixiangd@nvidia.com), Xuanhong Chen (chenxuanhong@sjtu.edu.cn), Kairui Feng (kelvinfr@tongji.edu.cn)

⁺These authors contributed equally to this work.

ABSTRACT

太阳能的采用对于实现净零排放至关重要。然而，许多工业和商业参与者在决定是否应采用分布式光伏-电池系统时仍面临困难，这主要是因为缺乏快速、低成本且高分辨率的辐照度预测。在这里，我们介绍了 SunCastNet，这是一个轻量级的数据驱动预报系统，可提供 0.05°、10 分钟分辨率的表面向下太阳辐射（SSRD）未来 7 天内的预测。SunCastNet 与强化学习（RL）结合用于电池调度，相比鲁棒决策制定（RDM），它可以将操作遗憾减少 76 – 93%。在 25 年的投资回溯测试中，它使每个地区的十个高排放工业部门中有五个达到了 12% 内部收益率（IRR）的商业可行性阈值。这些结果表明，高分辨率、长周期的太阳能预报可以直接转化为可衡量的经济效益，支持近乎最优的能量操作并加速可再生能源部署。

介绍

全球能源系统正朝着碳中和方向发展，太阳能光伏（PV）作为增长最快的可再生能源之一正在崛起¹⁻³。中国的目标是到 2050 年将太阳能发电渗透率提高到 40% 以上^{4,5}。实现这样一个雄心勃勃的目标既依赖于持续的产能扩张，也取决于在消费层面管理太阳能资源固有波动性的能力⁶⁻⁹。对于工业消费者而言，太阳能预报的质量决定了




Figure 1. SunCastNet 太阳能预测管道结合了用于工业经济评估的 RL 框架。 (a) SunCastNet 框架：该系统从 IFS/GFS（在 0.25° 分辨率下以 6 小时间隔的 73 个大气变量）开始，通过一个四阶段序列（即 SunCastNet）进行处理：(i) 使用天气预报和 SFNO，利用 73 个输入变量预测全球循环，生成分辨率为 0.25° 的每 6 小时场；(ii) 使用时间插值和 ModAFNO，将粗略的预报从每 6 小时分辨率精炼到每小时分辨率，使用连续两个大气状态（共 146 个变量）以及 9 个辅助字段（总共 155 个输入通道 73 个输出通道）；(iii) 使用太阳辐射诊断和 AFNO，将 31 个关键大气场映射到每小时的地表向下短波辐射（SSRD）；和 (iv) 使用降尺度分析和 CorrDiffSolar，将 57 个输入通道转换为校准过的大范围东亚-太平洋观测数据的分辨率为 0.05° 、10 分钟间隔的 SSRD 场。(b) 经济评估框架：这些高分辨率预测随后被嵌入基于 RL 的电池管理系统中，该系统整合了太阳能发电量、电力需求和价格信号以推导出最优的充电和放电策略。通过与完美信息和稳健决策（RDM）基线进行比较，该框架量化了预报技能对运营遗憾、基础设施规模以及工业部门长期投资回报的影响。分析集中在覆盖 $47-19.05^\circ\text{N}$, $97-124.95^\circ\text{E}$ 区域的中国。

他们每天的电池操作和电网互动情况，从而驱动了他们对投资光伏项目的长期决策¹⁰⁻¹⁴。工业消费者必须提前数天规划电池操作以在峰谷上网电价下保持盈利，这需要长时间范围、高分辨率的太阳能预测，而这往往是数值天气预报（NWP）无法提供的^{15,16}。

近期基于 AI 的天气模型如 FourCastNet¹⁷、GraphCast¹⁸ 和 Pangu-Weather¹⁹ 现在实现了与 NWP 相当，甚至超越其能力的全球 0.25° 和每小时尺度的预测技能²⁰⁻²⁵。许多研究人员现在正从低分辨率的研究中获取发现来开发高分辨率天气预报²⁶⁻²⁸，因此解决一系列下游管理问题。从低到高分辨率天气预报的过渡面临着显著挑战，包括计算需求呈指数级增长、缺乏高分辨率观测以及误差累积^{29,30}。各种方法，从任务特定的微调³¹、诊断模块^{32,33}到多源数据集成²⁸，目前正在被探索。然而，这些进展对于需要预测具有周前时间范围和站点级精度的工业消费者来说仍然不足³⁴⁻³⁶。

这里，我们介绍了在 NVIDIA Earth-2 平台上开发的**太阳预报网络**，这是一个将 AI 气象预报领域的最新进展转化为高分辨率（ 0.05° ，10 分钟）长周期（7 天）太阳能预测和下游决策支持的顺序框架（图 1a）。预测组件被组织为四个反映大气过程的连续阶段^{37,38}：(i) 球面傅里叶神经算子（SFNO），它以每 6 小时一次 0.25° 的分辨率模拟全球循环³⁹，(ii) 调制自适应傅里叶神经算子（ModAFNO），将粗略的六小时状态插值到每小时的变化⁴⁰，(iii) 基

于 AFNO 的诊断模型³²，直接将关键大气场映射到向下表面太阳辐射（SSRD）上，这对于每小时 0.25 $\ddot{r}$ 的光伏发电输出⁴¹至关重要，并且 (iv) CorrDiffSolar 模块，将 (iii) 中的 SSRD 降尺度至 0.05 $\ddot{r}$ 和 10 分钟间隔⁴²（见材料与方法），并与高分辨率 SSRD 数据进行基准测试⁴³。综合来看，这一架构生成了连续的 7 天预报，并通过中国境内 2,164 个气象站进行了验证。相较于全球预报系统（GFS），SunCastNet 实现了 5-10% 更低的相对误差，20% 更高的互信息，并提高了预测的一致性。在单个 NVIDIA A100 GPU 上执行每 7 天天气预报大约需要 SunCastNet 25 分钟时间，预计大陆规模的每次预报成本约为 0.5 美元（以 2025 年美元计）。其训练和推理成本仍然远低于基础模型微调³¹、卫星到预报端到端方法²⁸以及传统数值天气预报⁴⁴。

然而，改进的预测指标（例如 RMSE）本身并不一定转化为经济价值^{~45}。一个太阳能预测悖论出现了，因为在许多地区，“晴天”是最常见的：一个始终预测“晴天”的简单模型可能达到约 85% 的准确性，但它仍然会导致电池运营商在未能提前充满电的情况下，在阴天造成显著损失。这种不对称性解释了为什么预报“准确率”有时会误导^{~46-49}。当预报无法可靠地检测到这些关键的多云时段时，操作员需要求助于稳健决策（RDM）^{~50-52}，这是一种以不确定集合驱动的方法群组，维持防御性储备以最小化最大潜在遗憾。只有当预报包含更多有见地的内容时，随机优化驱动方法，如强化学习（RL）^{~53,54}，才能乐观地寻求平均收益。

在这里，我们评估了 SunCastNet 的操作和经济价值（图 1b），并与 GFS 进行了比较。为了实现 25 年的经济回溯测试，我们首先在整个 25 年期间以每 10 分钟的分辨率生成 7 天预测，并且每隔 6 小时发布一次预报，这大约需要 15,000 个 A100 GPU 小时并产生了约 43 TB 的数据。对于给定的太阳能预测，RL 代理通过整合太阳能板和电池配置、需求以及价格信号来学习最优充放电策略（详见材料与方法）。这些短期策略被应用于跨越十个工业部门的 25 年投资回溯测试中，在其中系统性地探索了不同的容量配置。结果明确优于 GFS：与 RDM 相比，电池调度减少了 72-93% 的决策遗憾（GFS 为 43 - 66%，50% $\pm$ 25% 分位数），并且将多个代表性的太阳能项目从“不可行”转变为“盈利”的长期投资分析中。我们的分析还表明预测范围长度对于实现经济价值至关重要：一个 2 天的范围仅减少不到 40% 遗憾，而 7 天的范围在许多地区减少了超过 70% 的遗憾，这证明了延长范围显著增强了系统效益。这些发现表明，更高的空间（0.05 $\ddot{r}$ 对比 0.25 $\ddot{r}$ ）、更精细的时间（10 分钟对比 1 小时）分辨率和较长的预测范围从根本上增加了工业太阳能采用的经济利益。

结果

SunCastNet 预测能力

在建立了 SunCastNet 流水线（图 1）后，我们首先考察其对 SSRD 的核心预测能力。图 2 评估了 SunCastNet 跨多个提前时间和季节的 SSRD 预测技能。面板 2a 显示了一个典型春季日（2020 年 1 月 16 日）5 公里分辨率下的预测。地图展示了由上午 3 点发布的预报在中午 12 点本地时间预测的 SSRD，提前时间为 1 天、2 天、3 天、5 天和 7 天。SunCastNet 的预报重现了在卫星衍生地面实况（GT）中显而易见的太阳辐照度的大空间梯度，包括与中国南部地区云层覆盖相关的辐射强度下降。尽管随着提前时间的增长，预测偏差逐渐显现出来，但整体上与地面实况的空间对应关系即使是在 7 天的预测范围也仍然稳健。面板 2b 展示了对一个典型夏日日（2020 年 7 月 20 日）进行相同实验的结果，在该实验中 SunCastNet 捕捉到了中国北部地区高辐照度区域和长江流域由强云层引起的梯度。与前述春季日的预测类似，局部云结构稍微失真，但大尺度模式一致。这突显了模型在季节性预测能力上的连贯性，即使夏季条件下对流变异性更高。

面板 2c 通过中国境内每日峰值 SSRD 在 12:00 本地时间的年度相对误差来量化预测技能。大多数地区的误差保持在 20% 以下，即使是在 7 天提前量的情况下也是如此。其最大值（>30%）集中在南部和沿海地区，在这些地方云动力学特别难以预测。误差的空间分布表明，在受大范围动态影响而非局部对流影响的北部和内陆地区，SunCastNet 的表现最为可靠。

图 3 比较了 SunCastNet（0.05 $\ddot{r}$ ，10 分钟）和 GFS^{44,55}（0.25 $\ddot{r}$ ，1 小时，SSRD 由向下行短波辐射通量 DSWRF 转换而来）在中国 2,164 个站点观测值的预测情况。面板 3a 显示了当对所有站点进行平均时，两种模型的预测误差随预报时效增加而增大。SunCastNet 的中位相对误差从 2 天预报时的大约 13% 增加到 7 天预报时的 20%，而




Figure 2. SunCastNet 在不同季节和预测期对 SSRD 的预报技能。 (a) 显示了典型春季某天 (2020 年 1 月 17 日) 5 公里分辨率的预测结果, 在当地时间 12:00 (24 小时制) 时的 SSRD, 根据早上 3:00 发布的预报分别给出了 1、2、3、5 和 7 天后的预测值, 并与基于卫星数据的真实地面情况 (GT) 进行了比较。 (b) 与 (a) 相同, 但针对的是典型夏季某天 (2020 年 7 月 22 日) 的情况。 (c) 预报技能作为预报提前时间的函数表示, 以每年每天峰值 SSRD 在 12:00 当地时 (24 小时制) 相对误差 (RE) 的形式展示; 阴影部分表示了不同地点的误差水平。

GFS 错误则从 22% 增长至 28%。SunCastNet 在所有预报时效下保持比 GFS 约低 5 – 10% 的误差。它的 $50 \pm 25\%$ 四分位数范围也一直更窄 (例如, 2 天时为 7 – 24%, 而 7 天时为 9 – 37%), 相比之下 GFS (2 天时为 16 – 33%, 7 天时为 18 – 50%) 显示出跨站点更为稳定的性能。

我们对 2020 年 8 月至 2025 年 8 月间 SunCastNet 和 GFS 在中国三个代表性子区域生成的数据进行了详细评估 (图 S1; 数据补充中的背景场)。在东北、东南和西南中国地区, SunCastNet 在传统上被认为对太阳能预测最具挑战性的三种气象条件下始终优于 GFS: 由秸秆燃烧引起的气溶胶扰动⁵⁶ (例如 2020 年 2 月), 未解析到 25 公里的台风结构⁵⁷ (例如 2020 年 7 月的台风哈格比), 以及频繁出现的逆温和盆地效应⁸。值得注意的是, SunCastNet 的 ModAFNO-诊断模块似乎利用第一帧太阳辐射来隐式推断输入中表示的相关过程 (如气溶胶、云微物理), 从而能够做出比 GFS 更准确的判断, 而 GFS 的辐射诊断并未考虑这些因素。

图板 3b 展示了 2023 年 4 月初某一站点的一个典型降雨期。从每日最大辐照度来看, 两种模型都捕捉到了与降雨事件相关的辐照度急剧下降。然而, 我们观察到在大多数情况下它们的时间结构有所不同。具体来说, SunCastNet 每小时有波动, 而 GFS 倾向于产生程式化的三角形日变化周期, 在预报发布后上升, 在中午达到峰值, 然后在下午下降。此外, GFS 在每个晴天的下午倾向于高估辐照度 (①, ②和③在图板 3b 中; 另见补充数据中的其他站点和案例)。可能的原因是 GFS 包含的小时级信息有限, 因为底层的湿度和云诊断仅在准静态 6 小时周期⁵⁸ 通过快速辐射传输模型 (RRTM)⁵⁹ 更新。因此, GFS 的名义上的每小时分辨率可能比 6 小时数据包含的新信息更少, 而 SunCastNet 探索了更精细的时间嵌入依赖关系。我们可以预期 GFS 的 SSRD 预报中包含的信息少于 SunCastNet。

为了进一步探究这一假设, 面板 3c 使用互信息 (MI) 评估预测结果。与均方误差 (MSE) 等标准误差度量不同, 后者量化了预测值和观测值之间的点对点偏差, MI 评估的是真实序列的底层时间结构在预测中被保留了多少。在 2,164 个站点中的 97%, SunCastNet 的 MI 高于 GFS, 平均比值约为 1.2 (大约多共享了 20% 的真实信息)。这表




Figure 3. SunCastNet 和 GFS 对 SSRD 的预测对比。 (a) 日照辐射预报相对误差与预测提前时间（2 至 7 天）的关系，涵盖中国 2,164 个站点。红线和阴影表示 SunCastNet 误差的中位数和四分位距（IQR，第 25 到 75 百分位），而蓝线和阴影表示 GFS 对应值。(b) 2023 年 4 月初一个站点（位于部分 c 中的紫色星号位置）的地表短波辐射时间序列示例。黑色线条显示地面真实测量值，红色线条显示 SunCastNet 预报结果，蓝色虚线显示 GFS 预报结果。(c) 预报与地面真实数据之间互信息的比值，颜色表示各个站点 SunCastNet 相对于 GFS 的比例；橙色/红色表示高于 1.0 的比值（SunCastNet 优于 GFS），蓝色表示低于 1.0 的比值。

明 SunCastNet 减少了预测误差并保持了更丰富的时间和多元依赖关系。因此更高的 MI 意味着 SunCastNet 为下游任务如可再生能源调度和运营管理工作提供了具有更大决策信息的预测。

决策下的 SunCastNet

基于图 3 中的信息导向比较，我们接下来考察预测内容的差异如何转化为决策结果。如果 SunCastNet 确实提供了比 GFS 更丰富和一致的信号，我们预期这些优势将能够在短期运营调度和长期投资策略中都得以体现。

我们首先将不一致性定义为在第一天发布的第二天预测辐照度与第二天自身发布的预测辐照度之间的差异。在图 4a – b 中，SunCastNet 的不一致性远小于 GFS：大多数地区的误差保持在 20 W m⁻² 以下，很少超过 30 W m⁻²，而 GFS 显示出广泛的 30 – 50 W m⁻² 的不一致性，并且在长江流域和四川地区出现高于 50 W m⁻² 的热点。图 4c 展示了通过采样 30 天地面真实辐照度序列并报告标准差获得的基线。这个基线通常在多云地区超过 100 W m⁻²，表明系统的固有变异性。因此，无论是 SunCastNet 还是 GFS 都为决策者提供了更稳定、更有信息量的指导，但 SunCastNet 在时间上明显更为一致。

当预测不一致时，一个预测推荐的最优行动可能会与基于下一个预测的建议相矛盾。这导致了不稳定的运营策略、高昂的调整成本，并且在实践中会阻止操作员完全使用任何预测⁶⁰。相反，他们可能诉诸于保守的鲁棒优化，这种做法忽略了大部分预测信息但避免了重大财务损失。




Figure 4. 从预测一致性到 SunCastNet 和 GFS 的决策结果。 (a – b) 日预报不一致，定义为在第 1 天发布的第 2 天的预测辐照度与在第 2 天当天发布的该日预测之间的差异（红色表示较大的不一致性，蓝色表示较小）。(c) 来自卫星地面实况的 SSRD 月标准差，用作朴素可预测性基线（红色表示较高的变异性，蓝色表示较低）。(d – e) 强化学习 (RL) 电池管理策略在使用 SunCastNet 与 GFS 预报训练时所实现的决策遗憾百分比减少量，平均值取自 10 个代表性工业部门（汽车、电子、食品加工、纺织品、制药、化工、钢铁、纸张、水泥和玻璃）。(f – g) 从最小最大鲁棒决策制定 (RDM) 基线切换到使用 SunCastNet 或 GFS 预报的 RL 指导策略时的投资决策变化量（在 10 个行业中变化，红色表示更多的变化，蓝色表示更少的变化；范围为 1 至 5）。

面板 4d – e 定量分析了不同时间预测的运营效益与强化学习电池管理的关系。我们评估了十个代表性工业部门的电力需求。不同的预测用于训练强化学习策略，并以完美信息基准衡量遗憾值。与基于过去 30 天历史场景得出的 RDM 基线相比，SunCastNet 指导下的强化学习策略在中国大部分北部和东部地区实现了 76 – 93% ($50\% \pm 25\%$ 分位数) 的遗憾减少，在某些区域接近 100%。基于 GFS 的强化学习策略将遗憾减少了 43 – 66% ($50\% \pm 25\%$ 分位数)。这表明更高的信息含量和时间连贯性直接提升了短期运营效率。如图 S2 所示，这些改进在所有十个代表性工业部门中都具有稳健性。这些部门的空间模式各异，但在 SunCastNet 指导下的强化学习策略下均显示出显著的效率提升。

面板 4f – g 将分析扩展到长期投资结果。使用跨度超过 25 年的 ERA5 驱动的回溯预测，我们确定了超出商业可行性阈值 $IRR > 12\%$ 的特定行业太阳能-电池项目。在 SunCastNet 指导下强化学习 (RL) 的影响下，许多具有高辐照度变化率的地区（例如中国中部省份如河南、湖北和安徽）改变了态度：它们以前认为这些项目在 RDM 下是“不可行”的，但现在则认为这些项目在 SunCastNet 指导下的 RL 中是“盈利”的建议。面板 4f – g 显示，每个地区的投资决策最多有五个部门发生变化，相比之下，在 GFS 下通常只有两到三个部门变化。这表明改进的预测支持更好的日常调度，并扩大了可能被太阳能投资吸引的工业行为者和地理范围，提供了加速碳中性工业转型的实际途径。

尽管 SunCastNet 和 GFS 之间的比较展示了更高空间和时间分辨率的优势，但预报范围对数值天气预测和基于 AI 的天气预测来说是另一个同样重要的维度。如图 S3 所示，太阳能预报的经济效益强烈依赖于预报范围长度。仅有 1 – 2 天的提前期时，遗憾减少仍保持适度（通常低于 40%），为工业调度提供的支持有限。相比之下，3 – 5 天的范围则带来有意义的增长，遗憾减少上升至 40 – 60%。在 7 天范围内，效益变得显著，在许多地区超过 70%。根据这些结果，较长范围的预报对于工业太阳能-电池系统至关重要，因为基于分时 (TOU) 的“低谷充电—高峰放电”策略需要数天的提前计划以实现其全部经济效益。

讨论

我们开发了 SunCastNet，这是一个顺序 AI 框架，通过集成专门的神经算子和扩散模型生成高达 7 天的高分辨率 (0.05°, 10 分钟) 太阳能辐射预测。当在中国 2,164 个气象站进行验证时，与 GFS 相比，SunCastNet 输出了 5-10% 较低的相对误差，并且互信息提高了 20%，同时保持了优越的时间一致性。通过这些预测与电池管理的强化学习相结合，我们展示了改进的太阳能预测直接转化为经济价值：减少了 70-90% 的操作遗憾，并使每个地区的十个工业部门中的五个超过太阳能投资 12% 的内部收益率可行性门槛。这项工作提供了定量证据，表明 AI 驱动的太阳能预测改进可以通过在更广泛的地理和行业领域中使太阳能电池系统具有经济可行性来加速工业脱碳。

为了确保由 SunCastNet 驱动的 25 年回顾性实验（从 2000 年 8 月到 2025 年 8 月）不会因过度拟合 SunCastNet 训练期（2015 – 2020 年）而产生偏差，我们进行了额外的稳健性检查。具体来说，我们使用仅在 2020 年 8 月至 2025 年 8 月之间的数据重复了五次规划实验，该时间段涵盖了 SunCastNet 和 GFS 预测。如图 S4 所示，尽管遗憾减少的空间模式与 25 年实验略有不同，但在中国的大部分地区，SunCastNet 仍然一致地提供了显著更高的遗憾减少。值得注意的是，现代基于深度学习的天气预报系统是通过非常大的多年再分析数据进行训练的，这降低了传统过拟合的可能性^{17,61}。因此，稳健性测试展示了性能提升并非来源于更长的历史预测可用性或训练集重叠，而是来自真实预测质量的改进。

两个限制需要注意。首先，我们的评估局限于中国，对于观测数据更稀疏或气候条件不同的地区需要进一步验证。其次，虽然基于强化学习的指标突出了显著的经济效益，但实际可行性取决于监管结构。在中国背景下，目前大多数工业消费者不允许向电网售电，这限制了潜在回报。

最后，我们提倡能源应用中的预测评估应超越 RMSE。信息内容、时间一致性以及后悔值等度量标准更直接地将预测技能与经济结果联系起来。随着太阳能容量的扩大，这种评估对于模型开发和规划都将至关重要。

References and Notes

1. Davis, S. J. *et al.* Net-zero emissions energy systems. *Science* **360**, eaas9793 (2018).
2. Soergel, B. *et al.* A sustainable development pathway for climate action within the un 2030 agenda. *Nat. Clim. Chang.* **11**, 656–664, DOI: [10.1038/s41558-021-01098-3](https://doi.org/10.1038/s41558-021-01098-3) (2021).
3. Wang, Y. *et al.* Global spatiotemporal optimization of photovoltaic and wind power to achieve the paris agreement targets. *Nat. Commun.* **16**, 2127, DOI: [10.1038/s41467-025-57292-w](https://doi.org/10.1038/s41467-025-57292-w) (2025).
4. Lu, X. *et al.* Combined solar power and storage as cost-competitive and grid-compatible supply for china's future carbon-neutral electricity system. *Proc. Natl. Acad. Sci.* **118**, e2103471118, DOI: [10.1073/pnas.2103471118](https://doi.org/10.1073/pnas.2103471118) (2021).
5. Yan, J., Yang, Y., Elia Campana, P. & He, J. City-level analysis of subsidy-free solar photovoltaic electricity price, profits and grid parity in china. *Nat. Energy* **4**, 709–717, DOI: [10.1038/s41560-019-0441-z](https://doi.org/10.1038/s41560-019-0441-z) (2019).
6. Yin, J., Molini, A. & Porporato, A. Impacts of solar intermittency on future photovoltaic reliability. *Nat. communications* **11**, 4781, DOI: [10.1038/s41467-020-18602-6](https://doi.org/10.1038/s41467-020-18602-6) (2020).
7. Li, X., Mauzerall, D. L. & Bergin, M. H. Global reduction of solar power generation efficiency due to aerosols and panel soiling. *Nat. Sustain.* **3**, 720–727, DOI: [10.1038/s41893-020-0553-2](https://doi.org/10.1038/s41893-020-0553-2) (2020).
8. Jerez, S. *et al.* The impact of climate change on photovoltaic power generation in europe. *Nat. communications* **6**, 10014, DOI: [10.1038/ncomms10014](https://doi.org/10.1038/ncomms10014) (2015).
9. Huang, J., Li, W., Guo, L., Hu, X. & Hall, J. W. Renewable energy and household economy in rural china. *Renew. Energy* **155**, 669–676 (2020).
10. Sobri, S., Koohi-Kamali, S. & Rahim, N. A. Solar photovoltaic generation forecasting methods: A review. *Energy conversion management* **156**, 459–497, DOI: [10.1016/j.enconman.2017.11.019](https://doi.org/10.1016/j.enconman.2017.11.019) (2018).
11. Ahmed, R., Sreeram, V., Mishra, Y. & Arif, M. A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization. *Renew. sustainable energy reviews* **124**, 109792, DOI: [10.1016/j.rser.2020.109792](https://doi.org/10.1016/j.rser.2020.109792) (2020).
12. Das, U. K. *et al.* Forecasting of photovoltaic power generation and model optimization: A review. *Renew. Sustain. Energy Rev.* **81**, 912–928, DOI: [10.1016/j.rser.2017.08.017](https://doi.org/10.1016/j.rser.2017.08.017) (2018).
13. Miller, S. D., Rogers, M. A., Haynes, J. M., Sengupta, M. & Heidinger, A. K. Short-term solar irradiance forecasting via satellite/model coupling. *Sol. Energy* **168**, 102–117, DOI: [10.1016/j.solener.2017.11.049](https://doi.org/10.1016/j.solener.2017.11.049) (2018).
14. Coville, A., Zivin, J. G., Reichert, A. & Reitmann, A.-K. Quality signaling and demand for renewable energy technology: Evidence from a randomized field experiment. *J. Dev. Econ.* **176**, 103514 (2025).
15. Cui, C., Lonergan, K. E. & Sansavini, G. Policy-driven transformation of global solar PV supply chains and resulting impacts. *Nat. Commun.* **16**, 6742, DOI: [10.1038/s41467-025-61979-5](https://doi.org/10.1038/s41467-025-61979-5) (2025).
16. Corwin, K. A. *et al.* Solar energy resource availability under extreme and historical wildfire smoke conditions. *Nat. Commun.* **16**, 245, DOI: [10.1038/s41467-024-54163-8](https://doi.org/10.1038/s41467-024-54163-8) (2025).
17. Pathak, J. *et al.* Fourcastnet: A global data-driven high-resolution weather model using adaptive fourier neural operators. *arXiv preprint arXiv:2202.11214* (2022).
18. Lam, R. *et al.* Learning skillful medium-range global weather forecasting. *Science* **382**, 1416–1421, DOI: [10.1126/science.adi2336](https://doi.org/10.1126/science.adi2336) (2023).

19. Bi, K. *et al.* Accurate medium-range global weather forecasting with 3d neural networks. *Nature* **619**, 533–538, DOI: [10.1038/s41586-023-06185-3](https://doi.org/10.1038/s41586-023-06185-3) (2023).
20. Rasp, S. *et al.* Weatherbench 2: A benchmark for the next generation of data-driven global weather models. *J. Adv. Model. Earth Syst.* **16**, e2023MS004019, DOI: [10.1029/2023MS004019](https://doi.org/10.1029/2023MS004019) (2024).
21. Chen, K. *et al.* FengWu: Pushing the skillful global medium-range weather forecast beyond 10 days lead. *arXiv preprint arXiv:2304.02948* DOI: [10.48550/arXiv.2304.02948](https://doi.org/10.48550/arXiv.2304.02948) (2023).
22. Sun, X. *et al.* A data-to-forecast machine learning system for global weather. *Nat. Commun.* **16**, 6658, DOI: [10.1038/s41467-025-62024-1](https://doi.org/10.1038/s41467-025-62024-1) (2025).
23. Price, I. *et al.* Probabilistic weather forecasting with machine learning. *Nature* **637**, 84–90, DOI: [10.1038/s41586-024-08252-9](https://doi.org/10.1038/s41586-024-08252-9) (2025).
24. Kochkov, D. *et al.* Neural general circulation models for weather and climate. *Nature* **632**, 1060–1066, DOI: [10.1038/s41586-024-07744-y](https://doi.org/10.1038/s41586-024-07744-y) (2024).
25. Nguyen, T., Brandstetter, J., Kapoor, A., Gupta, J. K. & Grover, A. Climax: A foundation model for weather and climate. *ICML* (2023).
26. Dueben, P. D. *et al.* Challenges and benchmark datasets for machine learning in the atmospheric sciences: Definition, status, and outlook. *Artif. Intell. for Earth Syst.* **1**, e210002, DOI: [10.1175/aies-d-21-0002.1](https://doi.org/10.1175/aies-d-21-0002.1) (2022).
27. Craig, M. T. *et al.* Overcoming the disconnect between energy system and climate modeling. *Joule* **6**, 1405–1417, DOI: [10.1016/j.joule.2022.05.010](https://doi.org/10.1016/j.joule.2022.05.010) (2022).
28. Bai, M. *et al.* Solorseer: Ultrafast and accurate 24-hour solar irradiance forecasts outperforming numerical weather prediction across the usa. *arXiv preprint arXiv:2508.03590* (2025).
29. Reichstein, M. *et al.* Deep learning and process understanding for data-driven earth system science. *Nature* **566**, 195–204, DOI: [10.1038/s41586-019-0912-1](https://doi.org/10.1038/s41586-019-0912-1) (2019).
30. Schultz, M. G. *et al.* Can deep learning beat numerical weather prediction? *Philos. Transactions Royal Soc. A* **379**, 20200097, DOI: [10.1098/rsta.2020.0097](https://doi.org/10.1098/rsta.2020.0097) (2021).
31. Lehmann, F. *et al.* Finetuning a weather foundation model with lightweight decoders for unseen physical processes. *arXiv preprint arXiv:2506.19088* (2025).
32. Carpentieri, A. *et al.* Data-driven surface solar irradiance estimation using neural operators at global scale. *arXiv preprint arXiv:2411.08843* DOI: [10.48550/arXiv.2411.08843](https://doi.org/10.48550/arXiv.2411.08843) (2024).
33. Xia, P. *et al.* Accurate nowcasting of cloud cover at solar photovoltaic plants using geostationary satellite images. *Nat. Commun.* **15**, 510, DOI: [10.1038/s41467-023-44666-1](https://doi.org/10.1038/s41467-023-44666-1) (2024).
34. Bodnar, C. *et al.* A foundation model for the earth system. *Nature* **641**, 1180–1187, DOI: [10.1038/s41586-025-09005-y](https://doi.org/10.1038/s41586-025-09005-y) (2025).
35. Allen, A. *et al.* End-to-end data-driven weather prediction. *Nature* **641**, 1172–1179, DOI: [10.1038/s41586-025-08897-0](https://doi.org/10.1038/s41586-025-08897-0) (2025).
36. Ben Bouallègue, Z. *et al.* The rise of data-driven weather forecasting: A first statistical assessment of machine learning-based weather forecasts in an operational-like context. *Bull. Am. Meteorol. Soc.* **105**, E864–E883, DOI: [10.1175/BAMS-D-23-0162.1](https://doi.org/10.1175/BAMS-D-23-0162.1) (2024).
37. Stengel, K., Glaws, A., Hettinger, D. & King, R. N. Adversarial super-resolution of climatological wind and solar data. *Proc. Natl. Acad. Sci.* **117**, 16805–16815, DOI: [10.1073/pnas.1923328117](https://doi.org/10.1073/pnas.1923328117) (2020).

38. Hess, P., Drüke, M., Petri, S., Strnad, F. M. & Boers, N. Physically constrained generative adversarial networks for improving precipitation fields from earth system models. *Nat. Mach. Intell.* **4**, 828–839, DOI: [10.1038/s42256-022-00540-1](https://doi.org/10.1038/s42256-022-00540-1) (2022).
39. Bonev, B. *et al.* Spherical fourier neural operators: Learning stable dynamics on the sphere. In *International conference on machine learning*, 2806–2823 (PMLR, 2023).
40. Leinonen, J., Bonev, B., Kurth, T. & Cohen, Y. Modulated adaptive fourier neural operators for temporal interpolation of weather forecasts. *arXiv preprint arXiv:2410.18904* DOI: [10.48550/arXiv.2410.18904](https://doi.org/10.48550/arXiv.2410.18904) (2024).
41. Antonanzas, J. *et al.* Review of photovoltaic power forecasting. *Sol. energy* **136**, 78–111, DOI: [10.1016/j.solener.2016.06.069](https://doi.org/10.1016/j.solener.2016.06.069) (2016).
42. Mardani, M. *et al.* Residual corrective diffusion modeling for km-scale atmospheric downscaling. *Commun. Earth & Environ.* **6**, 124, DOI: [10.1038/s43247-025-02042-5](https://doi.org/10.1038/s43247-025-02042-5) (2025).
43. Letu, H. *et al.* A new benchmark for surface radiation products over the east asia–pacific region retrieved from the himawari-8/ahi next-generation geostationary satellite. *Bull. Am. Meteorol. Soc.* **103**, E873–E888 (2022).
44. Kalnay, E. *et al.* The ncep/ncar 40-year reanalysis project. *Bull. Am. Meteorol. Soc.* **77**, 437–472, DOI: [10.1175/1520-0477\(1996\)077<0437:TNYRP>2.0.CO;2](https://doi.org/10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2) (1996).
45. McGovern, A. *et al.* Using artificial intelligence to improve real-time decision-making for high-impact weather. *Bull. Am. Meteorol. Soc.* **98**, 2073–2090 (2017).
46. Winkler, R. L. Evaluating probabilities: Asymmetric scoring rules. *Manag. Sci.* **40**, 1395–1405 (1994).
47. Jose, V. R. R. Percentage and relative error measures in forecast evaluation. *Oper. Res.* **65**, 200–211 (2017).
48. Visser, L., AlSkaif, T., Khurram, A., Kleissl, J. & van Sark, W. Probabilistic solar power forecasting: An economic and technical evaluation of an optimal market bidding strategy. *Appl. Energy* **370**, 123573 (2024).
49. Campos, R. A., Martins, G. L. & Rüther, R. Assessing the influence of solar forecast accuracy on the revenue optimization of photovoltaic+ battery power plants in day-ahead energy markets. *J. Energy Storage* **48**, 104093 (2022).
50. Bertsimas, D., Brown, D. B. & Caramanis, C. Theory and applications of robust optimization. *SIAM review* **53**, 464–501 (2011).
51. Ben-Tal, A., Den Hertog, D., De Waegenaere, A., Melenberg, B. & Rennen, G. Robust solutions of optimization problems affected by uncertain probabilities. *Manag. Sci.* **59**, 341–357 (2013).
52. Kim, S. & Choi, D. G. A sample robust optimal bidding model for a virtual power plant. *Eur. J. Oper. Res.* **316**, 1101–1113 (2024).
53. Jiang, D. R. & Powell, W. B. Optimal hour-ahead bidding in the real-time electricity market with battery storage using approximate dynamic programming. *INFORMS J. on Comput.* **27**, 525–543 (2015).
54. Brown, D. B. & Smith, J. E. Unit commitment without commitment: A dynamic programming approach for managing an integrated energy system under uncertainty. *Oper. Res.* (2025).
55. Wu, Y., Zhang, X., Li, M. & Chen, Y. Evaluation of the global forecast system (gfs) model for surface solar radiation prediction. *Renew. Energy* **203**, 25–38, DOI: [10.1016/j.renene.2023.01.067](https://doi.org/10.1016/j.renene.2023.01.067) (2023).
56. Li, X., Wagner, F., Peng, W., Yang, J. & Mauzerall, D. L. Reduction of solar photovoltaic resources due to air pollution in china. *Proc. Natl. Acad. Sci.* **114**, 11867–11872, DOI: [10.1073/pnas.1711462114](https://doi.org/10.1073/pnas.1711462114) (2017).

57. Ceferino, L., Lin, N. & Xi, D. Stochastic modeling of solar irradiance during hurricanes. *Stoch. Environ. Res. Risk Assess.* **36**, 2681–2693 (2022).
58. NCEP, N. Global forecast system (gfs) documentation. https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gfs/documentation.php (2021). Accessed: 2025-09-03.
59. Clough, S. A. *et al.* Atmospheric radiative transfer modeling: A summary of the aer codes. *J. Quant. Spectrosc. Radiat. Transf.* **91**, 233–244 (2005).
60. Genov, E. *et al.* Balancing forecast accuracy and switching costs in online optimization of energy management systems. *arXiv preprint arXiv:2407.03368* (2024).
61. Keisler, R. Forecasting global weather with graph neural networks. *arXiv preprint arXiv:2202.07575* (2022).

竞争利益: 共同作者 (Z.D., B.B., A.C., J.L., T.K., J.S., R.C., Y.Zh., R.Zh. 和 F.H.) 是 NVIDIA Corporation 的员工, 该公司开发并销售计算硬件和软件产品。所有其他作者均与学术或研究机构有关联。本研究使用的计算资源, 包括用于模型训练和推理的 GPU, 都是由 NVIDIA 制造的产品。本文提出的方法和结果可能会被整合进未来 NVIDIA 提供的商业产品和服务中。

数据和材料可用性:

用于训练和评估我们的预测管道的大部分数据可以公开获得。ERA5 数据集可以从气候数据存储 (CDS) 获得 (<https://cds.climate.copernicus.eu>)。全球预报系统 (GFS) 的预报由环境预测中心 (NCEP) 提供, 可以通过 NOAA NOMADS 系统 (<https://nomads.ncep.noaa.gov>) 或 NCAR 研究数据中心 (<https://rda.ucar.edu>) 访问。东亚-太平洋长波/短波向下辐射数据集 (2016 – 2020) 可以从国家青藏高原数据中心获得 (<https://data.tpcd.ac.cn>)⁴³。地面太阳辐射测量数据通过天清数据服务系统从中国气象局 (CMA) 获得, 可通过国家气象信息中心申请 (<http://data.cma.cn>)。所有图表都是使用 Matplotlib、Xarray 和 NumPy 制作的, 地理地图则是使用 Cartopy 生成的。本研究分析的 42 个工业案例源自作者通过与行业合作直接访问的实际运营数据。这些数据集反映了代表性企业中的实际生产和电力需求模式, 确保了实用性。然而, 由于商业保密和与行业合作伙伴之间的非披露协议, 原始数据不能公开发布。

我们的 CorrDiffSolar 代码可在 <https://github.com/NVIDIA/physicsnemo> 获取。完整的 SunCastNet 框架 (包括 SFNO、ModAFNO、太阳辐射诊断和 CorrDiffSolar) 可在 <https://github.com/NVIDIA/earth2studio> 获得, 用于重现我们实验的可执行笔记本可在 https://github.com/kelvinfkr/Solar_Economy 获取。样本输出数据 (与补充数据相比分辨率更高) 以及指导 SunCastNet 推理的代码本可在 <https://doi.org/10.6084/m9.figshare.30070609> 获得。

补充材料

材料和方法

补充文本

图 S1 到 S4

表 S1 到 S2

参考文献 (61-80)

代码 S1

数据 S1