东西太平洋海表温度（SST）梯度在中太平洋NINO3.4海表温度预测技巧中的相对作用

Lekshmi S[1], Rajib Chattopadhyay*[1,2], D.S. Pai[3], M. Rajeevan[4], Vinu Valsala[2], K.S. Hosalikar[1], M. Mohapatra[5]

1. 印度气象局，浦那-411005 2. 印度热带气象研究所，浦那-411008 3. 气候变化研究所，喀拉拉邦戈德亚姆-686004 4. 国家地球科学研究中心，喀拉拉邦特里凡得琅-695011 5. 印度气象局，新德里-110003

*通讯作者电子邮箱：rajib@tropmet.res.in

摘要

西太平洋和东太平洋的海表温度主模态表现出显著但区域差异明显的梯度，这些梯度由波、内部动力学和人为变暖共同造成，并驱动太平洋中的海气相互作用。本文探讨了西太平洋和东太平洋海表温度梯度对中太平洋海表温度预测技巧的相对贡献；厄尔尼诺、拉尼娜或厄尔尼诺莫多基事件均会在该区域显著投影。为此，研究构建了一个基于卷积神经网络（CNN）的预测模型，用于预测NINO3.4 海表温度。基于CNN的预测模型在初始阶段使用空间滤波器，能够高效捕捉边缘或梯度，因此有助于理解海表温度空间梯度在预测技巧中的作用。研究报告了三个基于CNN的模型实验。第一个是CTRL实验，使用整个赤道太平洋区域的海表温度型。第二个和第三个模型仅使用赤道东太平洋和西太平洋区域的海表温度。该研究的另一项创新是通过对CNN滤波器进行随机初始化，生成了大量集合成员（5000个）。研究发现，随机初始化会影响预报技巧，并且每个提前期内5000个模型的相关技巧概率密度函数呈高斯分布。

模型实验表明，与东太平洋技巧相比，西太平洋海表温度模型能够提供更好的 NINO3.4 预测技巧。因此，基于海表温度型的卷积神经网络模型预报显示了海表温度空间型对厄尔尼诺-南方涛动预报的影响。

1. 引言

从厄尔尼诺-南方涛动（ENSO）预测的角度来看，中太平洋海表温度（SST）预测至关重要，尤其是对于厄尔尼诺莫多基事件（Ashok 等人，2007年）、中太平洋型厄尔尼诺（Yang 和 Jiang，2014年）以及遥相关的理解而言（例如，厄尔尼诺-南方涛动—季风预测遥相关（Sahoo 和 Yadav，2021年））。此外，动力模型有时也无法可靠地预测中太平洋海表温度（Wen等，2021年）。不同类型的厄尔尼诺-南方涛动以及厄尔尼诺莫多基事件，都会以不同强度投影到中太平洋海表温度上。中太平洋海表温度的空间分布受局地海气相互作用（即海表温度—对流反馈）（Zhang 等人，1995年；Xiang 等人，2013年）、海洋平流（Kug 等人，2009年）、风致温跃层变化（Ashok 等人，2007年）、副热带大气强迫（Yu 等人，2010年）以及波传播的延迟效应（Suarez 和 Schopf，1988年）控制。当前海表温度或厄尔尼诺-南方涛动的预测技巧，取决于模型有效表征西太平洋、东太平洋和中太平洋海洋中这些物理和动力过程的能力。东太平洋的温跃层较浅，海表温度较低。西太平洋的海表温度较高，温跃层较深。在较低海表温度区域，对流加热的作用较弱，因此海气相互作用也较弱，对大气过程的反馈较弱。例如，这种情况类似于东太平洋（例如参见 Suarez 和 Schopf（1988年）的图1）。在西侧，情况则有所不同。温跃层深得多，海气耦合再次减弱，与东太平洋的情况类似。然而，向西传播的罗斯贝波会在西边界发生反射，反射后的开尔文波向东传播。这能够在延迟模式下产生更强的温度变化（即 dT/dt）

位于中太平洋，并决定当地的海表温度型。赤道东太平洋和西太平洋的海表温度空间分布如何影响赤道海表温度或厄尔尼诺-南方涛动的预测技巧？众所周知，厄尔尼诺-南方涛动或海表温度的预测技巧具有季节性，而可预报性中的春季障碍已得到深入研究（Torrence and Webster，1998年；Mukhin 等人，2021年）。

海表温度梯度在海气相互作用和对流中的重要性众所周知（例如，Lindzen and Nigam，1987）。因此，了解中太平洋海表温度或厄尔尼诺-南方涛动的预测技巧对赤道太平洋上空温度分布的依赖关系十分重要（Liang 等人，2021）。近年来，中太平洋型厄尔尼诺和厄尔尼诺莫多基呈现出增长趋势（Ashok 等人，2007）。如前所述，东太平洋和西太平洋的海表温度演变型受不同过程支配，且东、西太平洋的温跃层深度存在很大[illegible]门开展本研究，利用西太平洋和东太平洋的海表温度型，展示中太平洋海表温度及厄尔尼诺-南方涛动的相对预测技巧。太平洋上的空间温度分布（或海表温度梯度）会如何影响预测技巧？这个问题可以从两个方面回答：首先，色散关系将某个模态的空间结构与其时间频率联系起来。罗斯贝模态具有独特的空间结构，该结构与其周期性相关，因此，这一模态的时间演变趋势与影响预测技巧的空间分布有关。其次，温度方程中的平流项与某个场的空间梯度有关，从而有助于计算温度趋势（例如 Ballester 等人，2016 年的方程 1）。海洋中的平流项决定了海洋—大气相互作用的一般低频振荡（Saravanan and McWilliams，1998）以及厄尔尼诺-南方涛动平流振荡器（Picaut 等人，1997）。动力模型可用于理解收支项，并且

可以计算不同物理项的贡献（Wen等，2021年）。然而，动力模型中的海表温度变化取决于大量物理过程，而预测海表温度异常的敏感性则受多种物理因素影响。通常，要分离出较简单的因素，需要精心设计实验。即使是最简单的振荡器模型（Zebiak and Cane，1987）也认识到东、西太平洋海表温度变化的重要性，但并未考虑空间梯度。例如，西太平洋振荡器（Weisberg and Wang，1997）以及中太平洋和东太平洋振荡器（Zebiak and Cane，1987）在概念表述上有所不同，分别描述了海盆西侧和东侧的海表温度变化。

因此，上述研究表明，在理解厄尔尼诺-南方涛动（ENSO）的背景下，海表温度空间模态发挥着重要作用。然而，众所周知，促成ENSO 动力学的过程存在不对称性，近期基于人工智能的方法的研究清晰地揭示了这些特征（Shin等，2022年）。在预测中太平洋海表温度方面，西太平洋与东太平洋海表温度分布型所发挥的作用尚不明确。更具体地说，平流梯度或形成东、西太平洋海表温度结构的波动模态如何影响预测技巧，仍不清楚。[illegible]因素会影响表面温度。由于不同物理因素的作用，西太平洋和东太平洋的变暖趋势存在差异（Park等，2022年），因此，变暖趋势会在这些区域施加不同的时间演变梯度。因此，评估表面温度分布型对预测技巧的敏感性十分重要。

深度机器学习模型越来越多地用于预测问题，目前也已应用于厄尔尼诺—南方涛动预测，其预测技巧可达6个月至18个月（Mu等，2021年；Ham等，2019年；Guo等，2020年）。深度学习模型非常

擅长分离空间梯度，与普通的全连接网络相比，其训练不会受到梯度消失问题的影响。基于卷积神经网络（CNN）的不同深度学习模型变体在厄尔尼诺—南方涛动预测中十分常见。在理解西太平洋和东太平洋空间型对预测中太平洋海表温度（或厄尔尼诺莫多基和中太平洋型厄尔尼诺）所起作用的背景下，可以使用基于CNN的模型。CNN模型具有空间滤波器和池化层，能够识别数据中的主要空间梯度。因此，在保留最重要信息的同时，可以对空间样本进行去噪。使用CNN的预测方案因而适合用于理解海表温度空间模式在厄尔尼诺—南方涛动预测中的作用。

本分析将构建一个简单（即“原味”）的卷积神经网络模型，用于预测中太平洋海表温度。不同于其他通过组合多个步骤来延长厄尔尼诺-南方涛动指数预测时效的模型，这里使用这种原味卷积神经网络模型，旨在了解西太平洋和东太平洋的SST空间型在预测中太平洋海表温度，进而预测中太平洋型厄尔尼诺或厄尔尼诺 Modoki 中所起的作用。这类简单模型基于基本且推荐的人工智能模型版本，便于理解厄尔尼诺-南方涛动事件的动力学（Shin等，2022年）。该预测模型采用传统的卷积神经网络方法构建，且仅使用一个变量（即海表温度）。预测实验旨在预测 NINO3.4 海表温度异常，该指标被视为厄尔尼诺-南方涛动的重要中太平洋指标。卷积神经网络的示意图见**图1**。此外，在本分析中，我们将采用卷积神经网络架构生成多集合预测模型，构建卷积神经网络预测模型的概率集合，并展示西太平洋和东太平洋海表温度在不同提前期预测NINO3.4海表温度异常的相对作用。

2. 方法与数据

(a) 基于卷积神经网络的预测方案

这里使用的卷积神经网络模型以太平洋区域的海表温度作为预测因子构建。该方法与 Ham 等（2019）的方法基本一致，不同之处在于区域范围有所不同，且输入矩阵还将最长 12 个月的海表温度滞后值作为不同通道。选择 12 个月滞后的原因如下：我们首先采用多元线性回归进行简单预测，以 NINO3.4 作为预测因子，预测不同提前期的同一指数。我们加入多个滞后值，以获得对滞后 1 个月的 NINO3.4 的最大预测技巧；随着提前期增加，相关技巧随之下降（**图7**中的黑线，后文也会讨论）。这被用作卷积神经网络预测的基准 CTRL实验（见下一节）。随后，卷积神经网络预测也采用相同的滞后期，假设在更长滞后期下，卷积神经网络至少能够提供更好的技巧。对于卷积神经网络模型，预测对象同样是 NINO3.4 区域的区域平均海表温度异常（170°–120° W，5° S–5° N 范围内的区域平均海表温度异常），提前期最长为 12 个月。

(b) 预测实验

为理解西太平洋和东太平洋海表温度的相对作用，设计了三项实验。第一项实验采用整个赤道太平洋（120°E-90° W,15° S-15° N）范围内的海表温度分布，作为 *CONTROL* 实验的标准参考。在该实验中，卷积运算覆盖整个太平洋区域，卷积滤波器也应用于整个区域。所选区域呈现出较强的梯度；通过对海表温度进行经验正交函数分析，可获得海表温度型。占主导地位的趋势模态和第二主导模态均呈现较强的梯度（趋势和 EOF型图未展示；详细分析请参阅 Barbosa 和 Anderson（2009）或 L'Heareux et al.,（2013）。此外，由于选取了整个太平洋区域，该模型

理应包含卷积运算所需的最多信息。本文将其称为 *CTRL* 预报。第二项实验基于东太平洋（160° W-90° W,15° S-15° N）海表温度距平构建卷积神经网络模型，称为 *EAST* 实验。该模型仅包含东太平洋海表温度梯度信息。第三项实验仅选取西太平洋区域（120° E-160° W,15° S-15° N），称为 *WEST* 实验。该模型仅包含西太平洋海表温度梯度信息。

对于三种采用皮肤温度数据的运行类型，我们分别创建了5000次集合试验；对于采用ERSST和COBE海表温度的运行，则创建了1000成员集合。后两种分析数据集主要用于验证（将在下一节讨论）。创建集合预报是为了了解滤波器权重随机随机化的敏感性。集合成员的生成方式是：模型拟合后生成并保存不同的滤波器权重。每个集合成员模型均单独保存。研究发现，这种权重随机化会影响卷积神经网络模型的可预报性技巧。这类似于动力模型运行对初始条件微小变化的敏感性（即混沌和非线性的影响），或计算过程中位移误差导致预报漂移的影响（Orrell 等，2001）。模型使用1950—2001年（612个月）的数据进行训练，测试时段为2002—2021年（228个月）。

三个实验的框图如**图 1**所示。如前所述，使用过去 12 个月的海表温度条件，预测提前期为 12 个月的 NINO3.4 海表温度距平条件。三个模型的基本组成部分保持不变，但输入区域大小因实验而异。模型由两个卷积层、两个池化层、一个展平层和一个全连接层组成。输入数据经卷积层滤波，该层包含 64 个滤波器，每个滤波器的卷积核大小为 3 X 3。输出

经过第一个卷积层后，使用步幅为 2 的 2 X 2 最大池化层进行空间池化。随后，将滤波后的数据再次输入卷积层，该层包含 128 个滤波器，卷积核大小为 3 X 3，并经过与上文相同的最大池化层。然后使用展平层将数据展平，再通过大小为 12 的全连接层得到输出。两个卷积层均使用双曲正切函数（tanh）作为激活函数，全连接层则使用线性激活函数。卷积层的初始权重使用 Glorot 均匀初始化器（亦称 Xavier 均匀初始化器）生成，随机种子设为 10，偏置初始化为零。模型运行所用超参数汇总见**表 1**。模型通过 Google Colaboratory 提供的计算资源，使用 tensorflow keras python 模块运行；该资源包含版本为 460.32.03 的 NVIDIA 系统管理接口（SMI）驱动程序。

（c） 数据

CNN 网络要求数据中不含未定义值。为实现本分析的目标，我们将使用地表温度数据。目前有多种海表温度再分析数据可供使用。然而，海表温度（SST）数据通常在陆地和小岛区域含有未定义值，而卷积网络程序不适合处理这些未定义值。因此，我们将使用皮肤温度作为主要数据，并将陆地温度已填充的海表温度数据（ERSST V5（ Huang 等人，2017）和 COBE海表温度（Hirahara 等人，2013））作为辅助验证数据，以检验我们的结论。月度 SST 数据取自美国国家环境预报中心第一再分析数据集的逐日皮肤温度数据，时间范围为 1950-2021年（Kalnay 等人，1996），区域覆盖热带太平洋区域（120° E-90°W,15° S-15° N）。皮肤温度数据代表海洋上的 SST 以及各大洲上的地

表温度。该数据与赤道太平洋上的 ERSST 分析和 COBE 海表温度分析高度相关（> 0.85，图未展示）。月度皮肤温度数据由逐日数据计算得出，距平则通过减去1950-2021年期间的气候平均值得到。作为预测对象的 NINO3.4 区域海表温度距平，是通过计算 NINO3.4 区域内皮肤温度距平的算术平均值得到的（170°–120° W, 5° S–5° N）。使用过去 12 个月的空间皮肤温度距平数据（下文简称 SST）作为预测因子，预测提前期为 12 个月的 NINO3.4 海表温度异常。

3. 结果

当前分析基于东、西太平洋与中太平洋之间假定的关系。为了初步了解这一关系，我们绘制了中太平洋一个小参考框（170°W–140°W，5°S–5°N）内平均海表温度与15°S–15°N范围内整个赤道太平洋海表温度的逐月滞后相关。滞后相关如**图2**所示。相关分析表明，较高相关性的分布型从滞后12个月到滞后1个月系统性地发生偏移，这说明在较长滞后期，西太平洋与该参考框相关。随着滞后期缩短，东太平洋的相关性增强。因此，这表明空间相关分布型会随滞后期发生偏移。中太平洋海表温度相关空间分布型的这一系统性偏移表明，要建立中太平洋海表温度预报模型，东、西太平洋都很重要。为了解西太平洋和东太平洋海表温度分布型的相对重要性，我们进行了第2节所述的实验。实验所选取的西太平洋和东太平洋区域如**图1（上图）**。所示。

a. *CTRL*实验：CTRL实验覆盖整个赤道太平洋区域（参见第2b节）。**图3a**（左图）展示了该实验的训练损失和测试损失，阴影部分表示集合成员之间的离散度。模型在训练和测试模式下均表现出符合实际的稳定性。**图4。**展示了包含5000个成员的集合在最长12个月提前期内的预报技巧。相关系数/标准化均方根误差（按测试时段内预测对象的标准差归一化） 绘于横轴，集合成员所占百分比绘于纵轴。每个子图代表一个提前期，展示最长12个月提前期内的技巧。在最长6个月提前期内，所有成员的相关系数均保持在0.5–0.6之间，归一化（标准化）均方根误差也均低于1。图中还展示了用于配置模型的损失函数——平均绝对误差（MAE）。平均绝对误差的增幅与均方根误差相似，但从滞后1个月到滞后8个月，其起始值较低。此外，误差分布的离散度随提前期增加。因此，该模型在最长6个月提前期内对NINO3.4的预报具有良好的保真度。值得注意的是，随着提前期延长，集合成员间相关系数的离散度增大，而均方根误差的离散度减小。这一相关技巧与动力模型的技巧相当（Barnston 等人，2011年、2012年）。然而，与采用多个预测因子或更大区域的当前先进卷积神经网络模型相比，该技巧仍较为有限，例如（Mu等，2021年；Ham等，2019年）。不过，本实验旨在考察西太平洋与东太平洋海表温度分布型对预报技巧的影响。因此，我们将其作为基准技巧。

b. *EAST* 实验：EAST 实验的技巧以与**图4。**类似的方式展示于**图5** 中。训练损失和测试损失显示在**图3b**的中间面板中。

对于东太平洋实验，技巧在提前期达到5个月时迅速降至0.5以下，而且均方根误差随提前期增加的速度也更快。其分布的离散度（即半宽）大于CTRL实验。平均绝对误差图也显示出与均方根误差图相似的结果。

c. 西部实验： WEST 实验的图以类似方式展示于**图6**中，训练损失和测试损失则显示在**图3c**右侧面板中。 可以看出，与 EAST 实验相比，WEST 实验的技巧显著更好，且与 CTRL 预测相当。此外，其离散度与 CTRL（即整个区域）相当。平均绝对误差分布图也显示，其离散度小于 EAST 实验。

上述结果以集合平均技巧的形式总结于**图7**中。结果表明，西太平洋实验在相关系数和均方根误差方面表现更好。在较短提前期（2—5个月），西太平洋实验具有更高的技巧。**图7**还展示了基于回归的预测模型对NINO3.4的预测技巧。该模型使用最多12个滞后的NINO3.4 海表温度作为预测因子（采用多元线性回归，将不同滞后作为同一训练时段中的不同变量）。这是用于验证CTRL运行的基准模型。可以看出，尽管在较短提前期（提前期1或2个月），CTRL卷积神经网络模型与基准模型的技巧相当，但在较长提前期，基于卷积神经网络的模型表现出更好的技巧（提前期超过6个月），这证实了基于卷积神经网络的机器学习预报的有效性。在较长提前期，预报海表温度和观测海表温度的功率谱显示，预报中的功率较弱（未显示）。这表明预报方差存在偏差，这是预报中常见的问题，需要进行方差订正（不过我们在此未进行订正，因为我们的目的是比较东西区域对技巧敏感性的影响）。观测到的NINO3.4

在测试时段，不同提前期预报中所有实验的NINO3.4 海表温度异常与预报距平（未进行任何偏差订正）如**图8所示。** 从图中可以清楚看出，随着提前期增加，各模型难以捕捉2015—2016年事件的极端峰值。此外，在较长提前期还可以观察到一些相位偏移（例如2011年的提前期5个月）。为了解厄尔尼诺或拉尼娜峰值期间的技巧，**图9**和**图10**分别展示了四次峰值厄尔尼诺和拉尼娜事件的模型预报结果。结果表明，在较长提前期，WEST运行的预报技巧在许多情况下更好。

4. 与其他再分析数据的比较

为了了解基于皮肤温度数据得出的结果的可信度，我们将结果与两种独立分析数据（ERSST 和 COBE 海表温度分析）的试验进行了比较。我们使用 ERSST 和 COBE 海表温度创建了一个1000成员集合。对这三种数据集的1000成员集合进行了比较。预测结果如**图11所示。** 从**图11b**和**11c**可以清楚看出，与皮肤温度（图**11a**）的情况相同，西部区域试验的相关系数高于东部区域试验。此外，对于美国国家环境预报中心皮肤温度和再分析数据，CTRL在六个月提前期的相关系数更高；但对于ERSST，相关系数并不显著。总的来说，结果表明东部和西部海盆在不同提前期呈现出不同的技巧。

5. 讨论与结论

上述分析旨在比较基于 WEST 和 EAST 运行的 NINO3.4预报技巧，并与整个区域（CTRL）运行的结果进行比较。主要实验采用美国国家环境预报中心皮肤温度数据，而非 ERSST 或 COBE 海表温度分析，因为

该区域岛屿上的海表温度数据缺失。分析中使用海表温度数据作为额外的验证来源，并以美国国家环境预报中心皮肤温度替代岛屿上的海表温度。进行这项比较的目的是考察西太平洋和东太平洋海表温度分布型对 NINO3.4 海表温度预测技巧的相对作用；NINO3.4 海表温度是代表不同厄尔尼诺-南方涛动类型的指数，包括中太平洋型厄尔尼诺分布型（例如 Ashok 等人，2007 年的表 2）。海表温度分布型体现为水平空间梯度，这些梯度由趋势、物理过程、平流特性或波动模态共同形成。众所周知，这些海表温度梯度会影响局地对流和地表风（Lindzen and Nigam，1987）。因此，海表温度梯度的分布型会影响预测技巧。本研究采用一种高效的、基于深度机器学习的梯度检[illegible]网络）来预测中太平洋的海表温度指数（NINO3.4）。卷积神经网络使用卷积运算，而卷积滤波器可识别空间域中的梯度（本研究中为海表温度梯度）。结果清楚表明，西太平洋海表温度分布型在决定 NINO3.4 海表温度预报技巧方面起主导作用。当模型拥有太平洋赤道海表温度分布型的完整信息时，整个区域（即 CTRL）运行的技巧最高；但仅考虑中东太平洋分布型时，技巧较为有限。非对称影响[illegible]的技巧高于 EAST）反映了太平洋厄尔尼诺-南方涛动动力学的复杂性，其他运用机器学习理解厄尔尼诺-南方涛动动力学作用的研究也讨论过这一点。CTRL 运行的预测技巧与动力模式预报相当（Barnston 等人，2011，2012），这表明西赤道太平洋的表层海表温度对 NINO3.4 分布型的可预报性起着重要作用。西太平洋和东太平洋的增暖趋势并不对称，决定表层及次表层海表温度分布的物理过程也有所不同。此外，中太平洋海表温度还受到罗斯贝波以及来自西太平洋的反射开尔文波的影响

边界，而且西部的温跃层更深。所有这些因素共同决定了海表温度型。我们在此表明，西侧和东侧的海表温度型在卷积神经网络模型中发挥着不同作用；这些模型利用空间滤波器，在初始层生成预测模型。

本研究的另一个重要结论是，卷积神经网络各层中空间滤波器的初始化会影响预测技巧。即使滤波器的权重只有微小差异（这是模型拟合层随机化造成的），也可能导致集合成员在较长提前期的技巧出现显著差异。因此，要理解预测技巧，就必须重视滤波器的随机化。要充分了解机器学习模型的预测效率，可能最好创建大量集合，并考察集合分布。

WEST与EAST试验之间的技巧差异，可归因于厄尔尼诺—南方涛动各位相及其转换与西太平洋罗斯贝波的延迟振子响应有关；罗斯贝波在西边界发生反射并转化为开尔文波后，会改变厄尔尼诺—南方涛动的位相。开尔文波在东太平洋反射后，以沿岸开尔文波的形式沿东海岸传播，这可能不像在WEST试验中那样有助于厄尔尼诺—南方涛动的振荡循环。对于本文考察的厄尔尼诺—南方涛动峰值事件（厄尔尼诺或拉尼娜），WEST运行的海表温度值略优于东部区域试验。对于某些单独的厄尔尼诺或拉尼娜事件，EAST、WEST或CTRL运行的技巧相当，这表明厄尔尼诺—南方涛动峰值事件的预报技巧可能取决于、也可能不取决于西太平洋和东太平洋的海表温度。本文未纳入次表层信息，其对厄尔尼诺—南方涛动预测技巧的作用将在后续研究中探讨。

致谢

LS感谢MRFP项目、地球科学部（MoES）和印度政府提供的研究奖学金支持。作者感谢CRS（IMD）主任给予的支持。作者感谢地球科学部（MoES）下属自治机构印度热带气象研究所（IITM）和印度气象局（IMD）提供的研究支持。作者还感谢IMD的DGM参与讨论并给予支持。

数据可用性声明

本文使用的原始皮肤温度、ERSST V5 和 COBE海表温度数据均可免费获取，相关信息已在文中说明。任何派生数据/代码均可在合理请求后提供。

利益冲突

作者声明不存在利益冲突。

参考文献

Ashok, K., Behera, S. K., Rao, S. A., Weng, H., 和 Yamagata, T.：Modoki厄尔尼诺及其可能的遥相关，《地球物理研究杂志：海洋》，112，https://doi.org/10.1029/2006JC003798，2007年。

Ballester, J., Bordoni, S., Petrova, D. 和 Rodó, X.：集合海洋同化产品所揭示的导致厄尔尼诺事件的热平流过程，《地球物理研究杂志：海洋》，121，3710–3729，https://doi.org/10.1002/2016JC011718，2016年。

Barbosa, S. M. 和 Andersen, O. B.：全球海表温度的趋势模式，《国际气候学杂志》，29，2049–2055，https://doi.org/10.1002/joc.1855，2009年。

Barnston, A. G., Tippett, M. K., L'Heureux, M. L., Li, S., and DeWitt, D. G.: 2002–11年实时季节性厄尔尼诺-南方涛动模型预测的技巧：我们的能力是否在不断提高？，《美国气象学会公报》，93, 631–651, https://doi.org/10.1175/BAMS-D-11-00111.1, 2011.

Barnston, A. G., Tippett, M. K., L'Heureux, M. L., Li, S., and DeWitt, D. G.: 2002–11年实时季节性厄尔尼诺-南方涛动模型预测的技巧：我们的能力是否在不断提高？，美国气象学会公报，93, ES48–ES50, https://doi.org/10.1175/BAMS-D-11-00111.2, 2012.

Guo, Y., Cao, X., Liu, B., and Peng, K.：使用集合经验模态分解的深度学习厄尔尼诺指数预测，Symmetry，12，https://doi.org/10.3390/sym12060893，2020年。

Ham, Y.-G., Kim, J.-H., and Luo, J.-J.：用于多年ENSO预报的深度学习，Nature，573，568–572，https://doi.org/10.1038/s41586-019-1559-7，2019年。

Hirahara, S., Ishii, M., and Fukuda, Y.：百年尺度海表温度分析及其不确定性，J. Climate，27，57–75，https://doi.org/10.1175/JCLI-D-12-00837.1，2013年。

Huang, B., Thorne, P. W., Banzon, V. F., Boyer, T., Chepurin, G., Lawrimore, J. H., Menne, M. J., Smith, T. M., Vose, R. S., and Zhang, H.-M.：扩展重建海表温度第5版（ERSSTv5）：升级、验证与比较，J. Climate，30，8179–8205，https://doi.org/10.1175/JCLI-D-16-0836.1，2017年。

Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K. C., Ropelewski, C., Wang, J., Leetmaa, A., Reynolds, R., Jenne, R., 和 Joseph, D.：《NCEP/NCAR 40年再分析项目》，美国气象学会公报，77，437–472，https://doi.org/10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2，1996年。

Kug, J.-S., Jin, F.-F. 和 An, S.-I.：《两类厄尔尼诺事件：冷舌型厄尔尼诺和暖池型厄尔尼诺》，《气候杂志》，22，1499–1515，https://doi.org/10.1175/2008JCLI2624.1，2009年。

L'Heureux, M. L., Collins, D. C., and Hu, Z.-Z.：热带太平洋海表温度的线性趋势及其对厄尔尼诺—南方涛动的影响，Climate Dynamics，40，1223–1236，https://doi.org/10.1007/s00382-012-1331-2，2013年。

Liang, X. S., Xu, F., Rong, Y., Zhang, R., Tang, X., 和 Zhang, F.：Modoki厄尔尼诺大多可提前 10 年以上预测，Scientific Reports，11，17860，https://doi.org/10.1038/s41598-021-97111-y，2021年。

Lindzen, R. S. 和 Nigam, S.：海表温度梯度在驱动热带低层风和辐合中的作用，《大气科学杂志》，44，2418–2436，https://doi.org/10.1175/1520-0469(1987)044<2418:OTROSS>2.0.CO;2，1987年。

Mu, B., Qin, B., 和 Yuan, S.：《ENSO-ASC 1.0.0：采用多变量海气耦合器的厄尔尼诺-南方涛动深度学习预测模型》，《地球科学建模发展》，14，6977–6999，https://doi.org/10.5194/gmd-14-6977-2021，2021年。

Mukhin, D., Gavrilov, A., Seleznev, A., 和 Buyanova, M.：《一种降低厄尔尼诺-南方涛动统计预测春季可预测性障碍的大气信号》，《地球物理研究快报》，48，e2020GL091287，https://doi.org/10.1029/2020GL091287，2021年。

Orrell, D., Smith, L., Barkmeijer, J., 和 Palmer, T. N.：《天气预报中的模式误差》，《非线性过程地球物理学》，8，357–371，https://doi.org/10.5194/npg-8-357-2001，2001。

Park, C., Kang, S. M., Stuecker, M. F., 和 Jin, F.-F.：辐射强迫下赤道太平洋西部和东部截然不同的表面增暖响应，《地球物理研究快报》，49，e2021GL095829，https://doi.org/10.1029/2021GL095829，2022。

Picaut, J., Masia, F., 和 du Penhoat, Y.：厄尔尼诺-南方涛动振荡特性的平流-反射概念模型，《科学》，277，663–666，https://doi.org/10.1126/science.277.5326.663，1997年。

Sahoo, M. 和 Yadav, R. K.：印度夏季风期间赤道中太平洋海表温度对印度北部降雨的调节作用，《国际气候学杂志》，41，6017–6030，https://doi.org/10.1002/joc.7165，2021年。

Saravanan, R. 和 McWilliams, J. C.：海洋-大气平流相互作用：一种解析随机模型及其对年代际变率的启示，《气候杂志》，11，165–188，https://doi.org/10.1175/1520- 0442(1998)011<0165:AOAIAA>2.0.CO;2，1998年。

Shin, N.-Y., Ham, Y.-G., Kim, J.-H., Cho, M. 和 Kug, J.-S.：将深度学习应用于理解 ENSO 动力学，《地球系统人工智能》，1–37，https://doi.org/10.1175/AIES-D-21-0011.1，2022。

Suarez, M. J. 和 Schopf, P. S.：ENSO 的延迟作用振荡器，《大气科学杂志》，45，3283–3287，https://doi.org/10.1175/1520- 0469(1988)045<3283:ADAOFE>2.0.CO;2，1988年。

Torrence, C. 和 Webster, P. J.：《厄尔尼诺/南方涛动持续性的年周期》，英国皇家气象学会季刊，124，1985–2004，https://doi.org/10.1002/qj.49712455010，1998年。

Weisberg, R. H. 和 Wang, C.：《厄尔尼诺-南方涛动的西太平洋振荡器范式》，《地球物理研究快报》，24，779–782，https://doi.org/10.1029/97GL00689，1997年。

Wen, C.、Kumar, A.、L'Heureux, M.、Xue, Y. 和 Becker, E.：《中太平洋经向热平流对厄尔尼诺-南方涛动发展的重要性》，《气候杂志》，34，5753–5774，https://doi.org/10.1175/JCLI-D-20-0648.1，2021年。

Xiang, B., Wang, B., 和 Li, T.：20世纪90年代末之后中太平洋驻波型增暖占主导地位的新范式，《Climate Dynamics》，41，327–340，https://doi.org/10.1007/s00382-012-1427-8，2013年。

Yang, S. 和 Jiang, X.：利用美国国家环境预报中心气候预测系统预测东太平洋和中太平洋厄尔尼诺-南方涛动事件及其对东亚气候的影响，《气候杂志》，27，4451–4472，https://doi.org/10.1175/JCLI-D-13-00471.1，2014年。

Yu, J.-Y., Kao, H.-Y. 和 Lee, T.：赤道中太平洋副热带相关的年际海表温度变率，《气候杂志》，23，2869–2884，https://doi.org/10.1175/2010JCLI3171.1，2010年。

Zebiak, S. E. 和 Cane, M. A.：《厄尔尼诺-南方涛动模型》，《月度天气评论》，115，2262–2278，https://doi.org/10.1175/1520- 0493(1987)115<2262:AMENO>2.0.CO;2，1987年。

Zhang, G. J., Ramanathan, V., and McPhaden, M. J.：《赤道太平洋中的对流-蒸发反馈》，《气候杂志》，8，3040–3051，https://doi.org/10.1175/1520-0442(1995)008<3040:CEFITE>2.0.CO;2，1995年。

图注

图1： 所用卷积神经网络模型的示意图。三个实验（CTRL、东部（EP）和西部（WP））采用相似的配置，仅区域大小不同。N表示样本量。对于过去12个月滞后期的每个SST空间型样本，模型输出未来12个月超前期的NINO3.4海表温度异常。

图2： 中太平洋小参考框（170°W - 140° W，5°S-5°N）内的面积平均海表温度与太平洋海表温度的相关系数空间分布。相关分布显示了非对称响应模式以及不同滞后期的位移。

图3： （a）CTRL、（b）EAST 和（c）WEST 实验的训练损失和测试损失随训练轮次的变化。

图4：CTRL实验在测试时段（2001—2021年）的验证指标（相关系数、归一化（标准化）均方根误差和平均绝对误差（MAE））随提前期的变化。图中每一行代表各面板右侧标注的一个提前期。概率分布（阴影部分）基于5000个集合成员。CTRL实验的区域大小参见图1。

图5：与图4相同，但对应EAST实验。

图6：与图4相同，但针对 WEST 实验。

图7：所有实验的集合平均验证指标（相关系数和标准化均方根误差）随提前期的变化。指标绘制在纵坐标上。

图8：2002—2021测试时段内，所有实验中观测海表温度距平（°C）与不同提前期的预报海表温度距平的时间演变。

图9：2002—2020年测试时段内厄尔尼诺峰值条件下模型预测在不同提前期的技巧。图中以不同柱形展示观测到的 NINO3.4 海表温度距平（°C）以及不同实验在不同滞后期（最长达6个月）的预报海表温度。

图10：与图9相同，但针对拉尼娜条件。

图11：比较使用不同海表温度数据训练的 CTRL、WEST 和 EAST 实验的相关系数和均方根误差，包括 (a) 美国国家环境预报中心皮肤温度、(b) ERSST V5海表温度和 (c) COBE海表温度。比较采用同一时期（2002—2021年）各1000个集合的平均值。

表 1：模型配置摘要

模型类型	卷积神经网络（CNN）
学习率	0.001
训练轮次	150
批次大小	4
损失函数	平均绝对误差（MAE）
优化器	RMSprop

图表

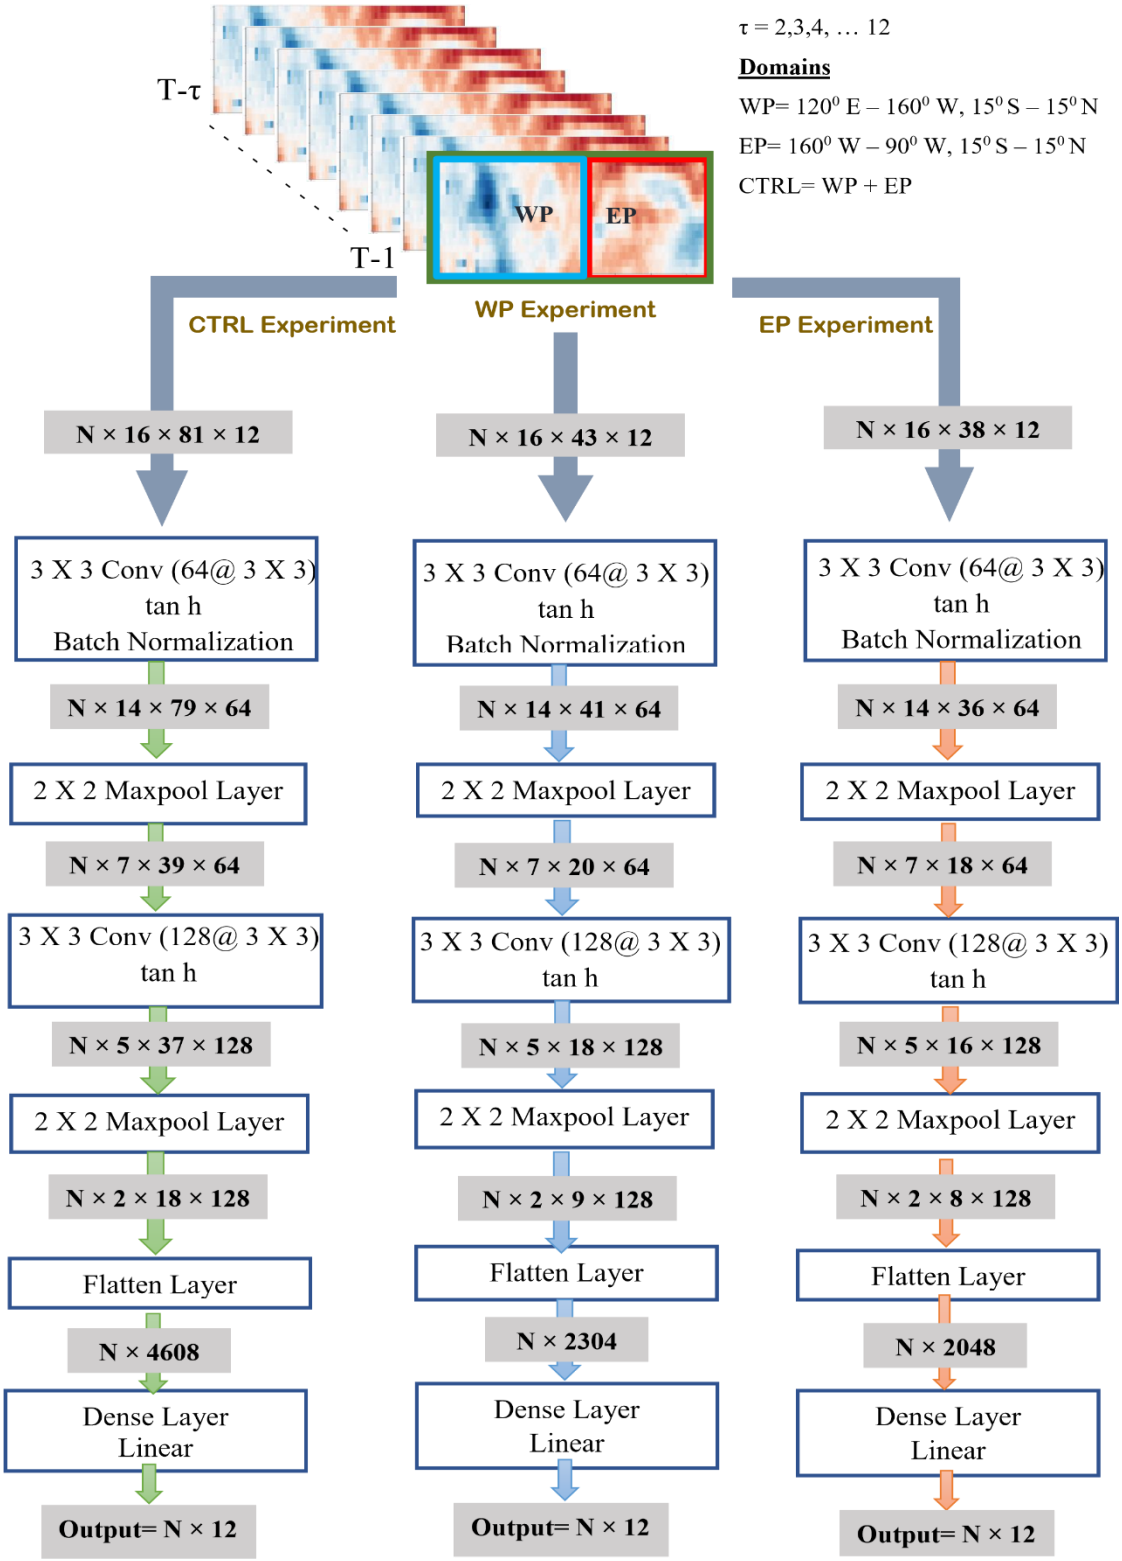


图1：所用卷积神经网络模型的示意图。三个实验（CTRL、东部（EP）和西部（WP））采用相似的配置，仅区域大小不同。N 表示样本量。对于过去12个月滞后期的每个 SST 空间型样本，模型会输出未来12个月超前期的 NINO3.4 海表温度异常。

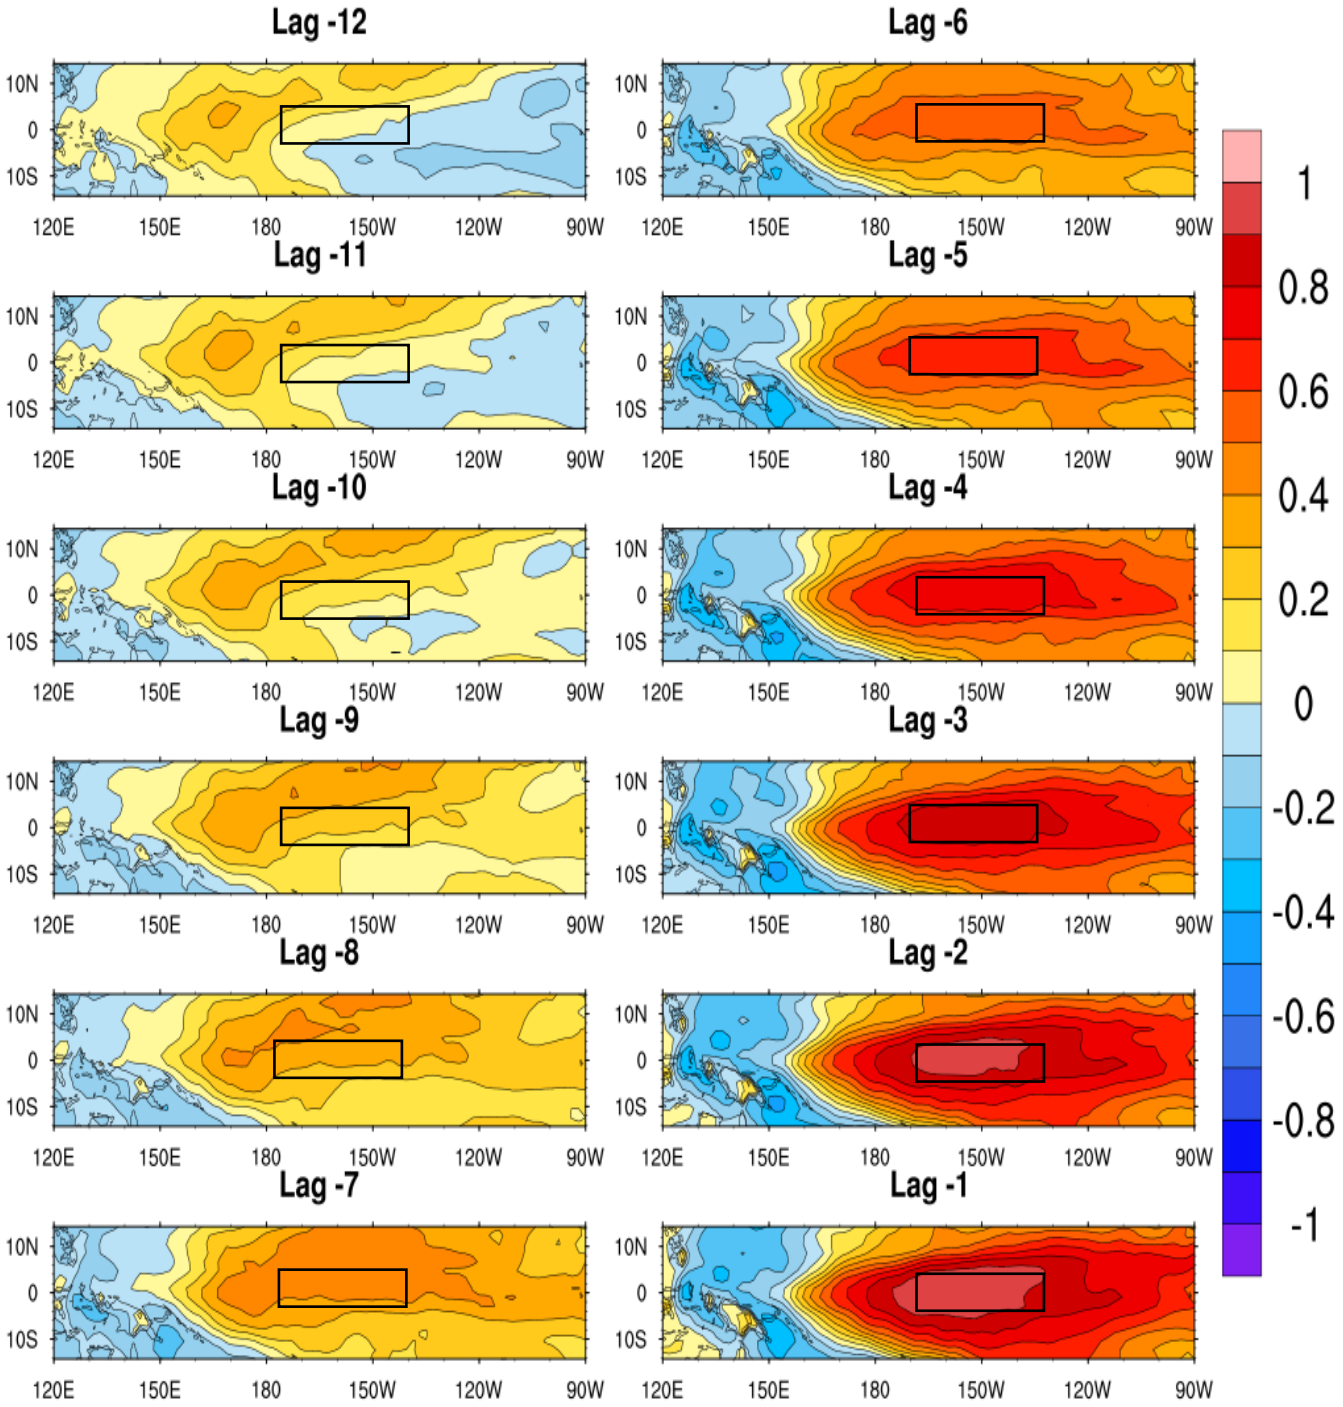


图 2：太平洋海表温度与中太平洋小参考框（*170°W - 140° W, 5°S-5°N*）内区域平均海表温度的相关系数空间分布。该相关分布显示了非对称响应模式及其在不同滞后下的变化.

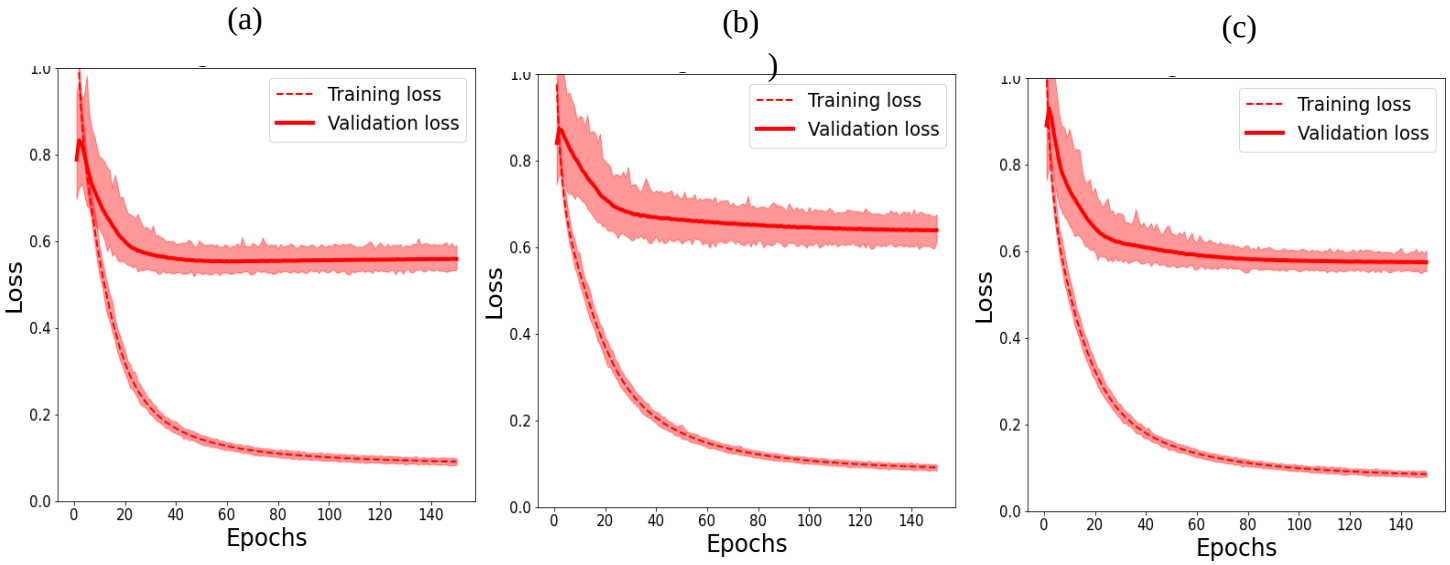


图3： (a) CTRL、(b) EAST 和 (c) WEST 实验的训练损失和测试损失随训练轮次的变化。

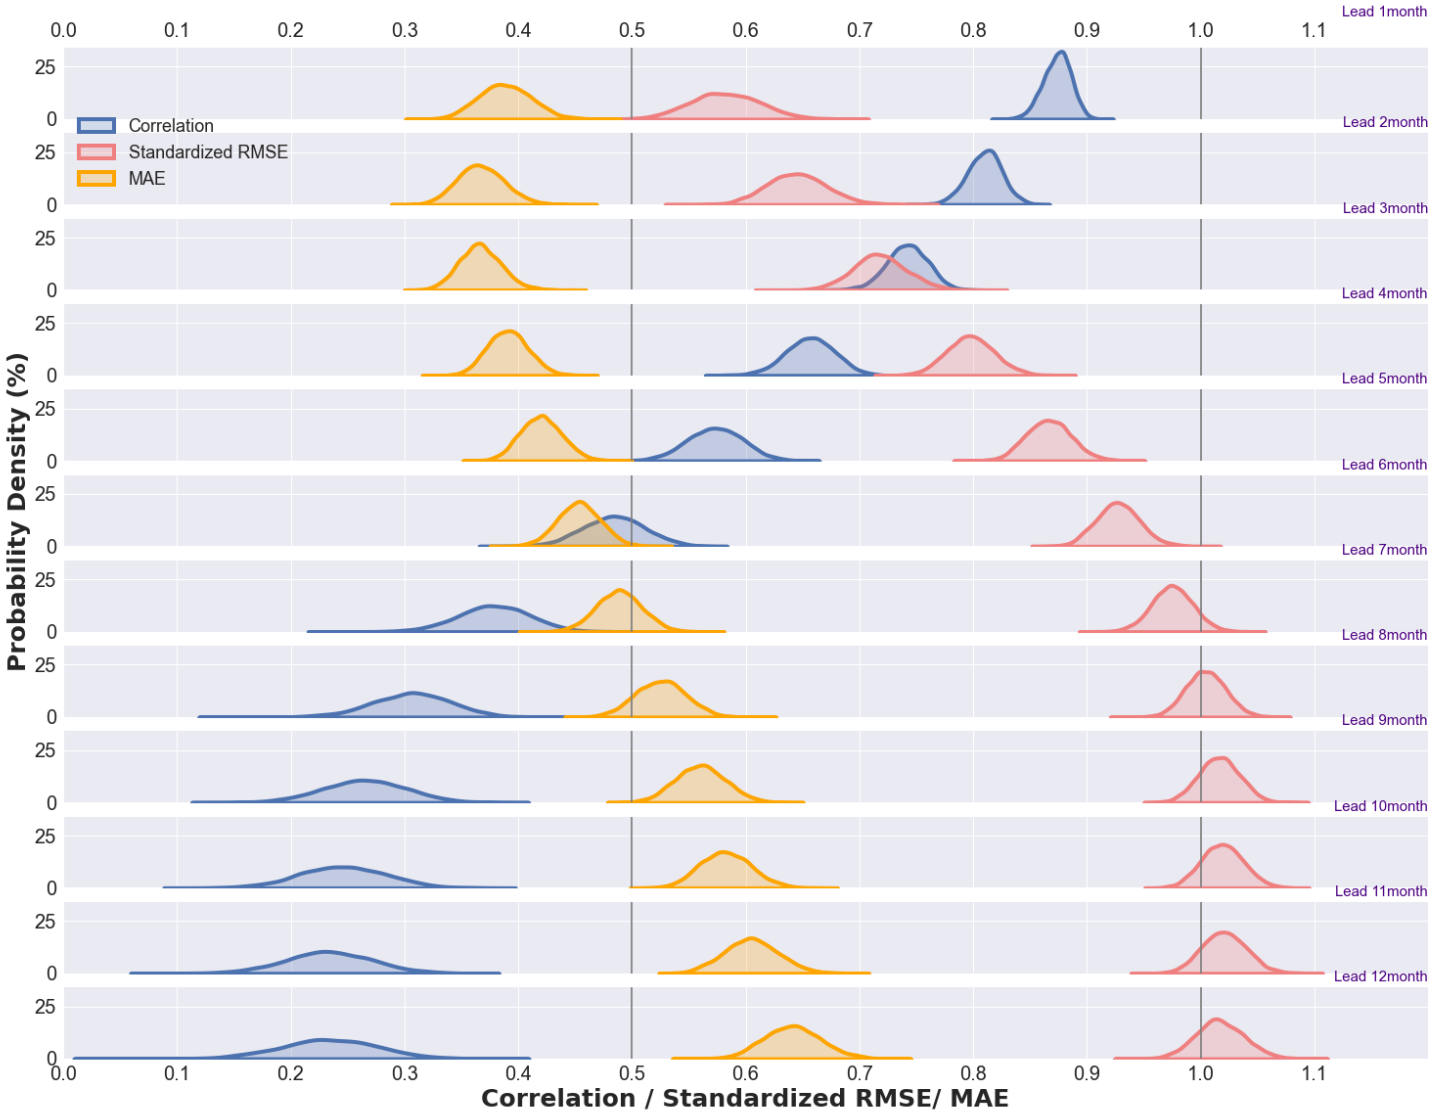


图4：CTRL实验在测试时段（2001—2021年）内，验证指标（相关系数、归一化（标准化）均方根误差和平均绝对误差（MAE））随提前期的变化。图中每一行代表一个提前期，具体见各面板右侧标注。阴影部分表示基于5000个集合成员得到的概率分布。CTRL实验的区域大小请参见图1。

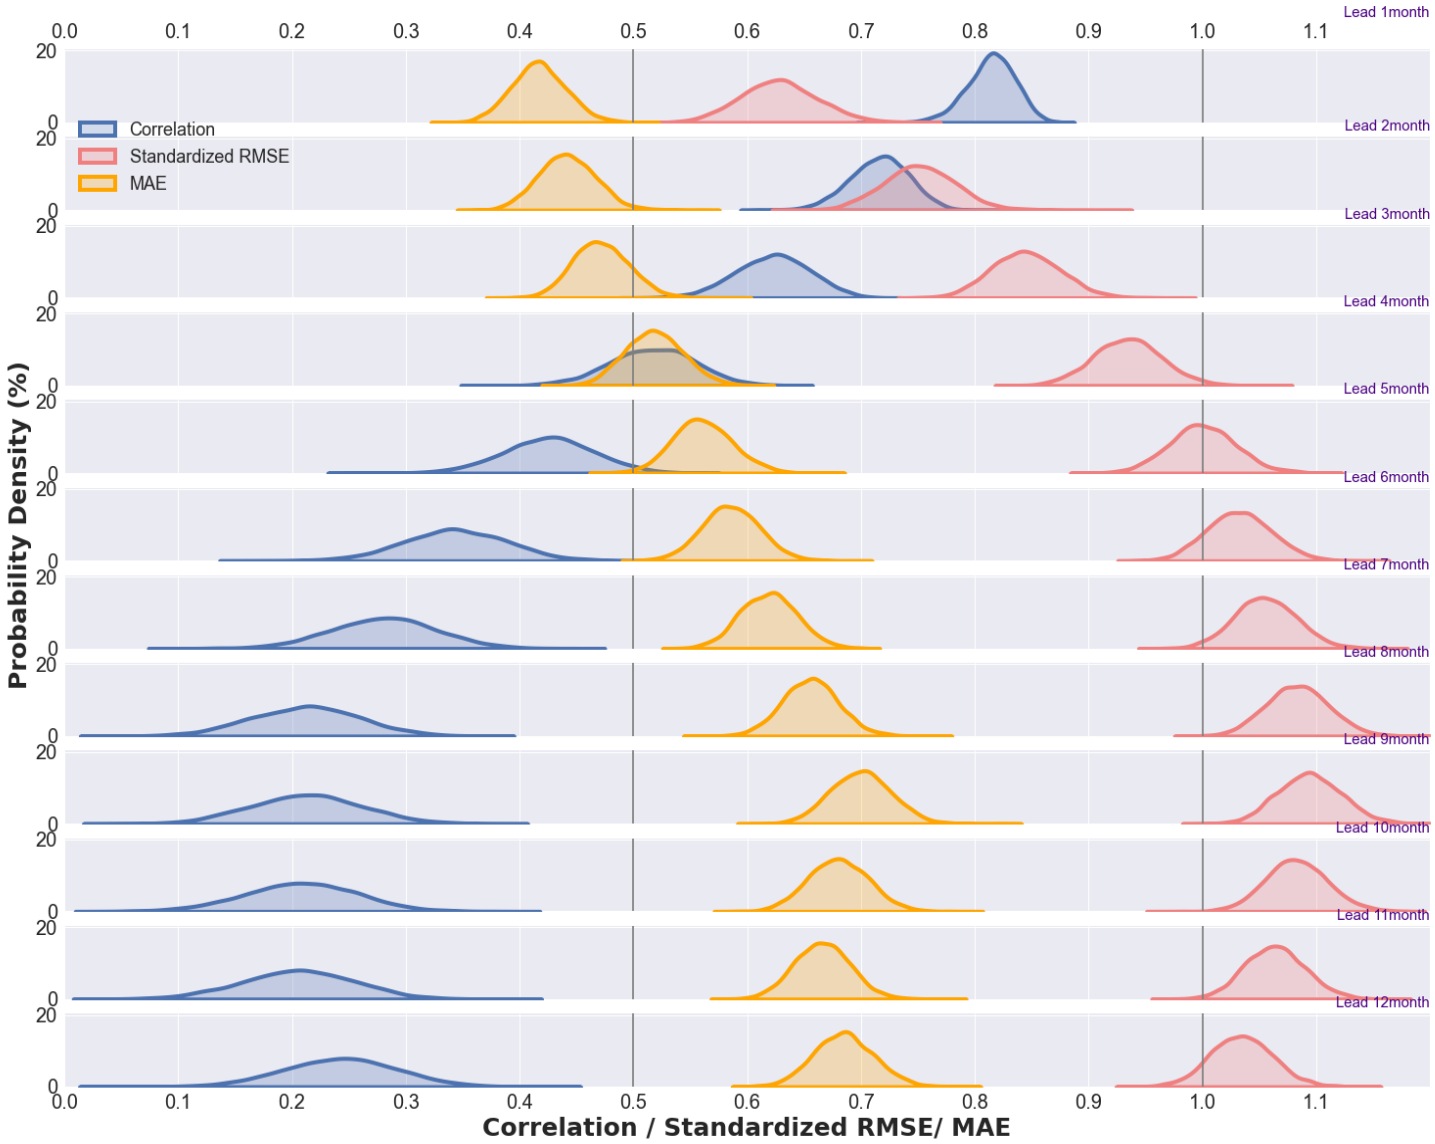


图5：与图4相同，但针对 EAST 实验。

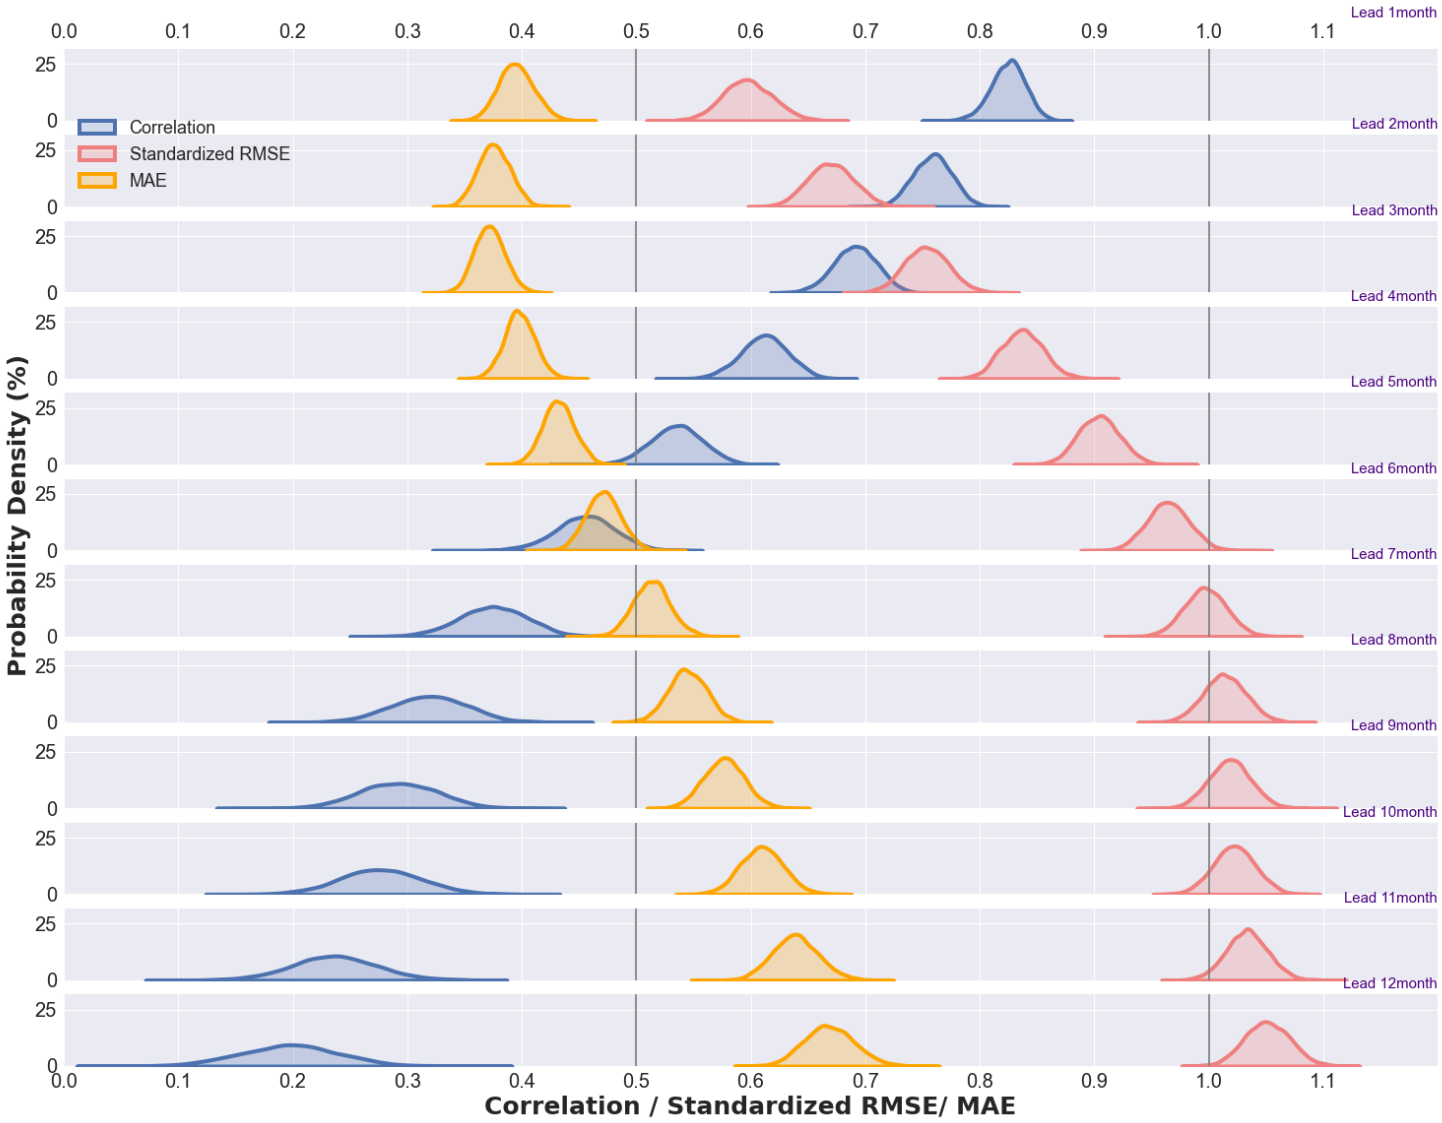


图6：与图4相同，但针对 WEST 实验。

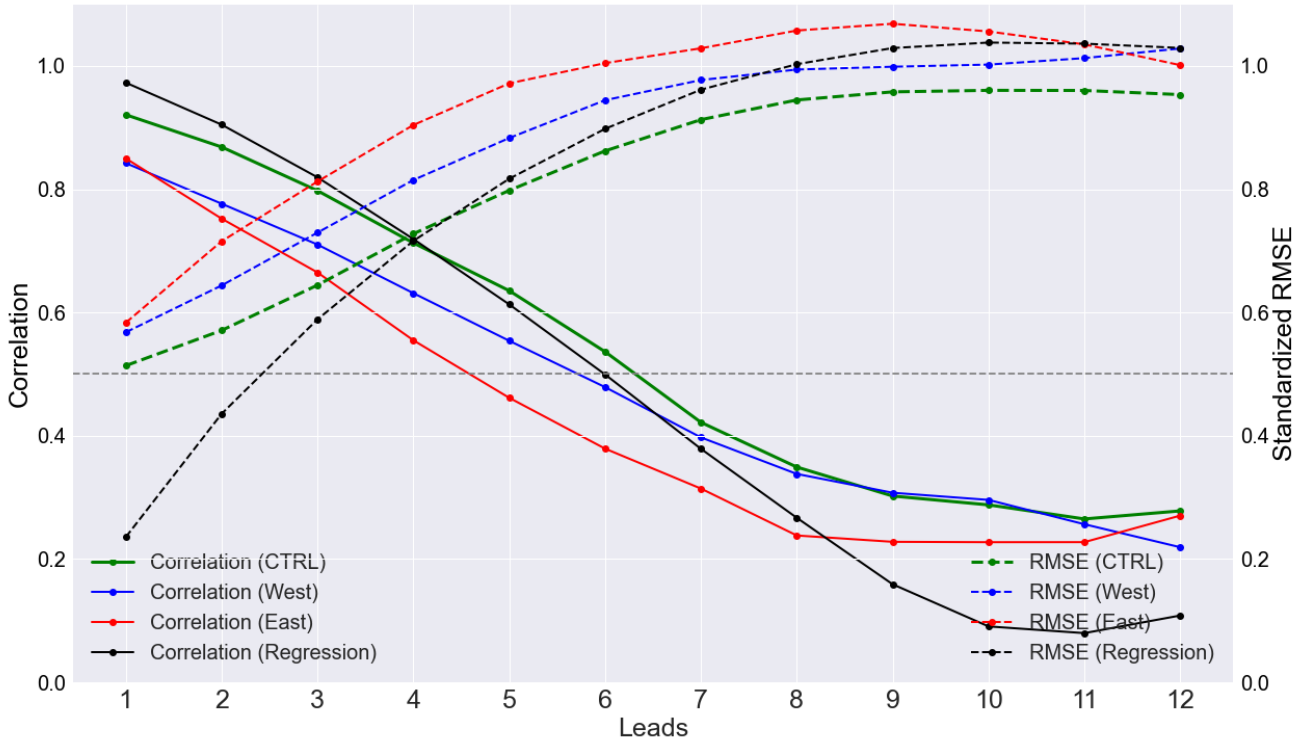


图7：所有实验的集合平均的验证指标（相关系数和标准化均方根误差）随提前期的变化。指标绘制在纵坐标上。

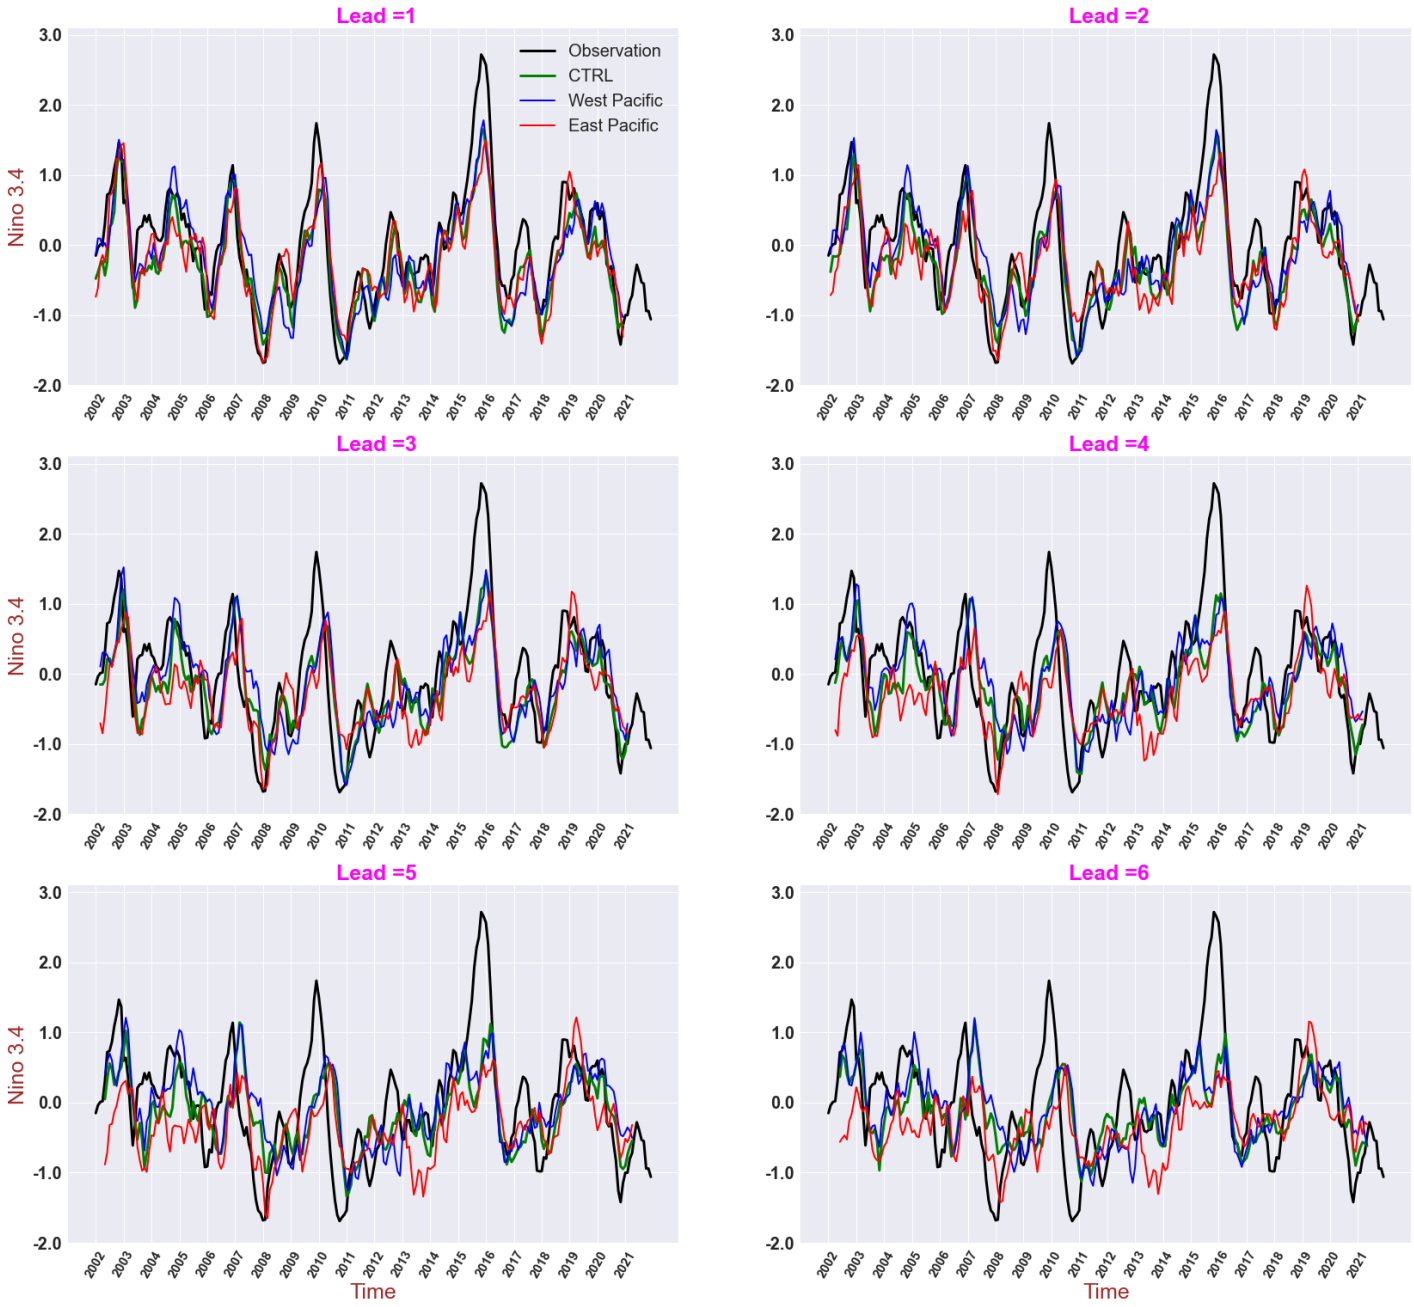


图8：2002—2021年测试时段内所有实验在不同提前期的观测海表温度距平（°C）与预测海表温度距平的时间演变。

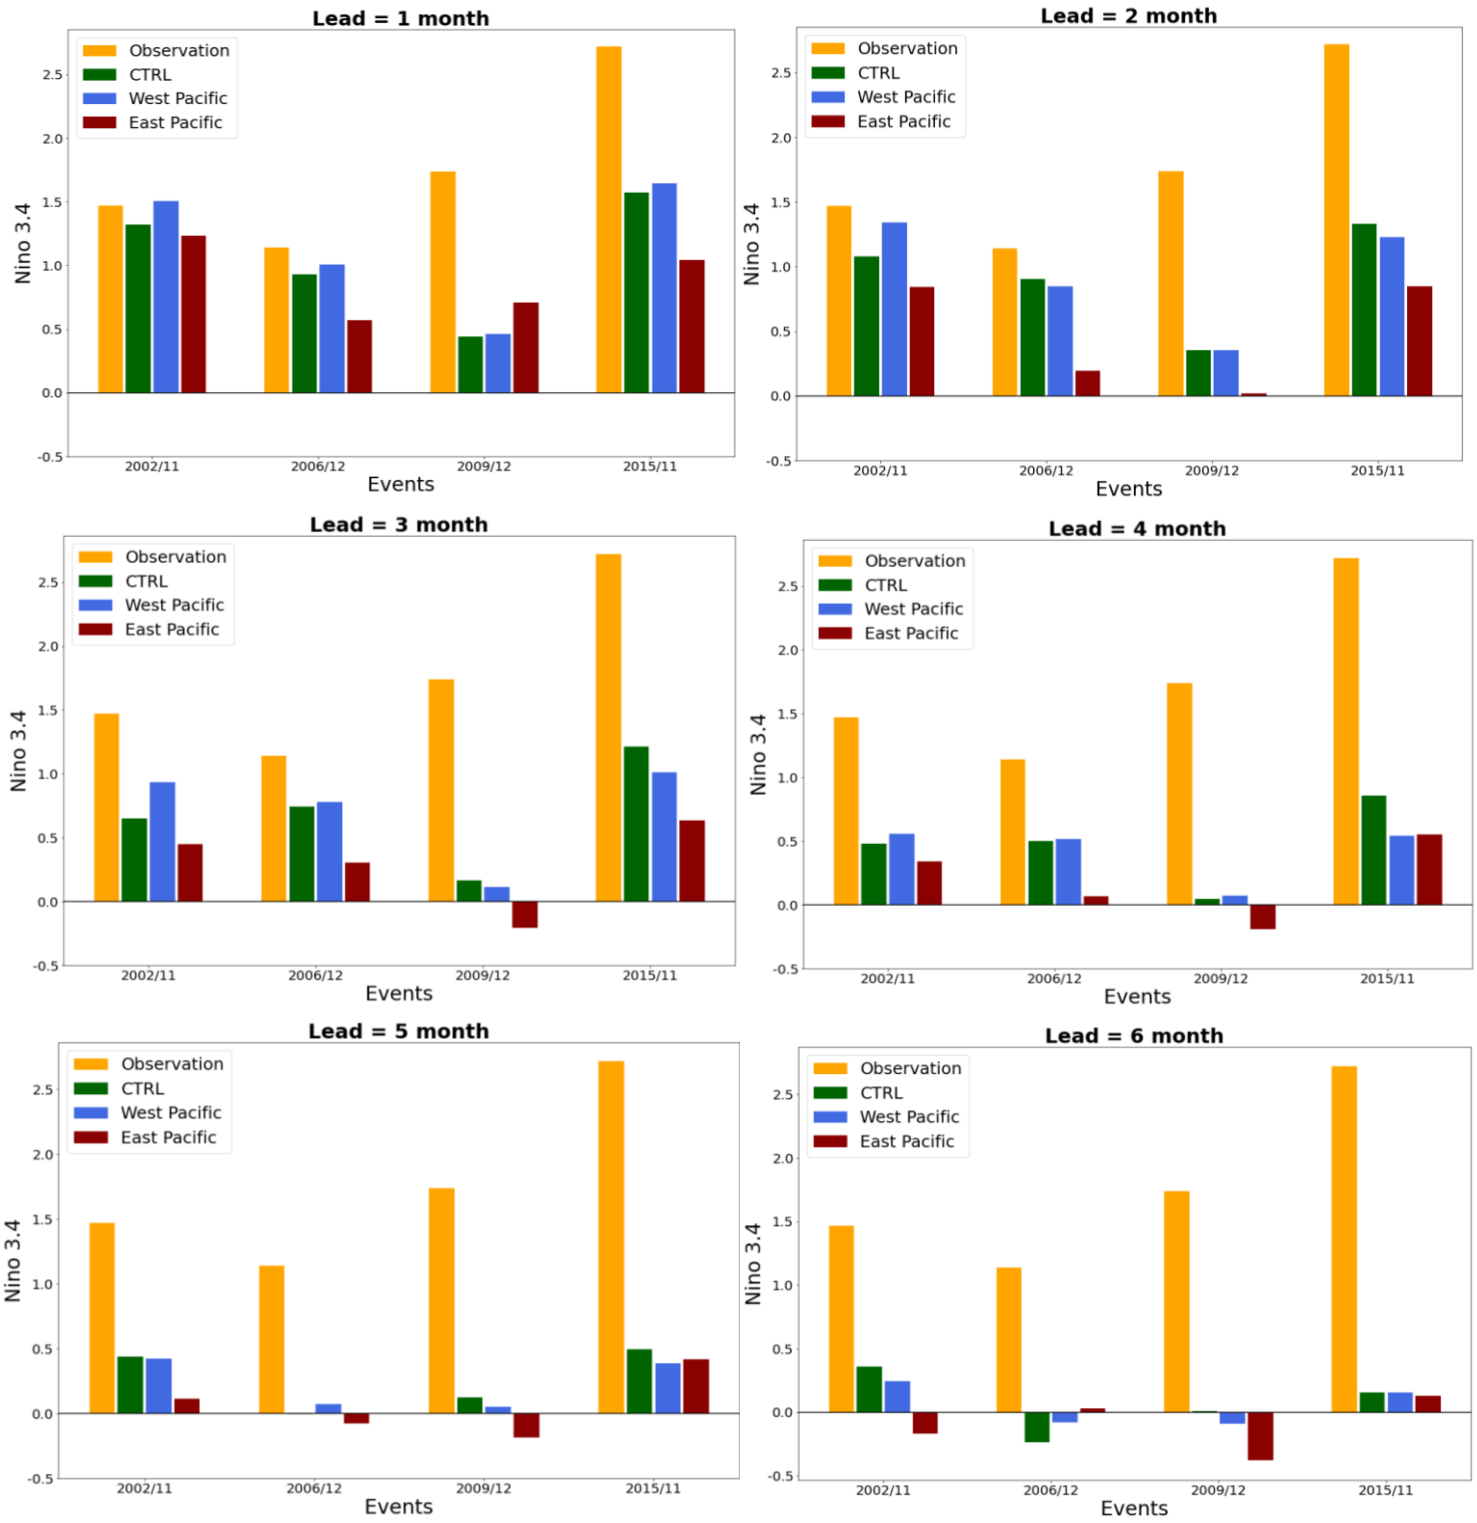


图9：2002—2020年测试时段内厄尔尼诺峰值条件下，模型预测在不同提前期的技巧。图中以不同柱形展示了观测到的 Nino3.4 海表温度异常（°C），以及不同试验在最长达6个月的不同滞后期预报的海表温度。

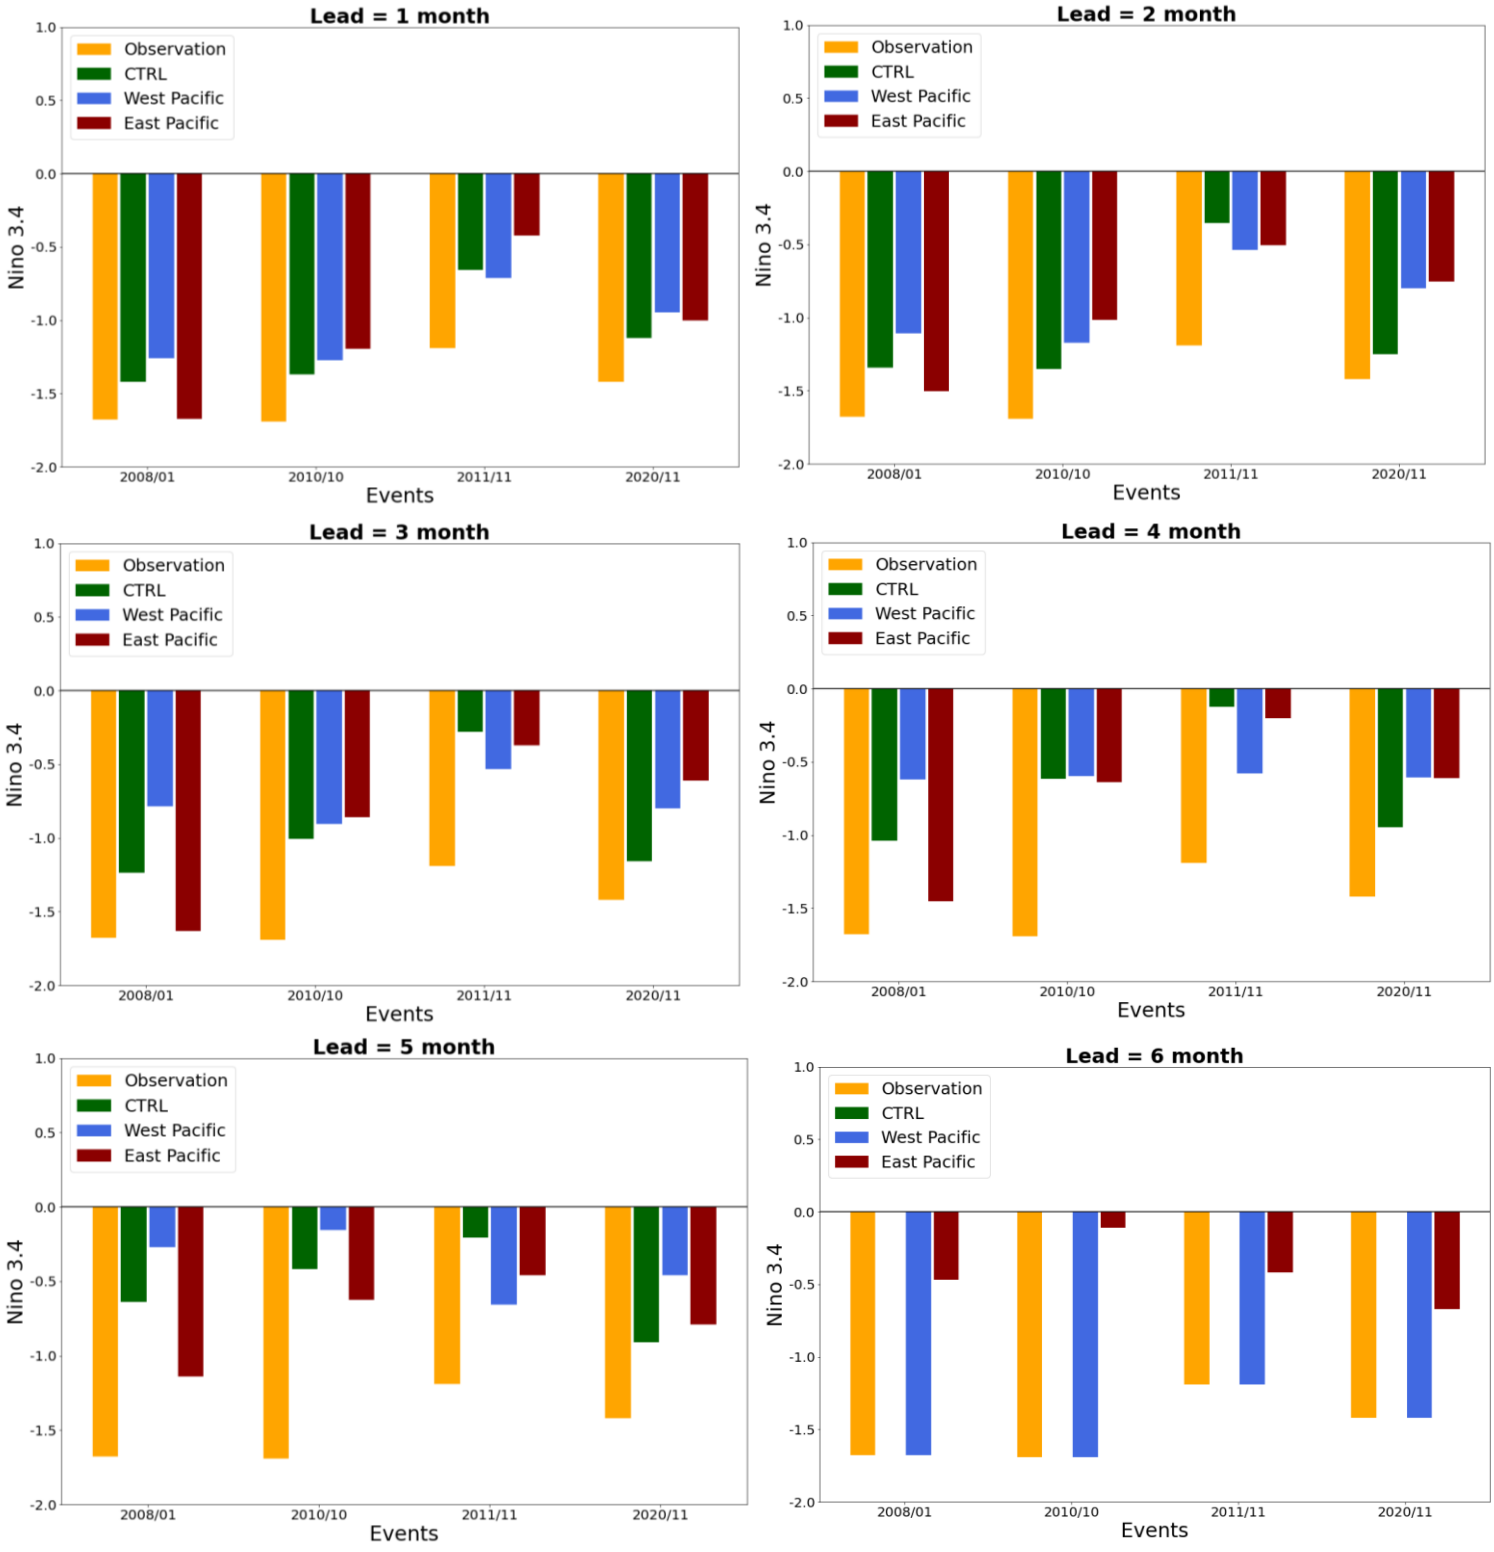


图10：与图9相同，但适用于拉尼娜条件。

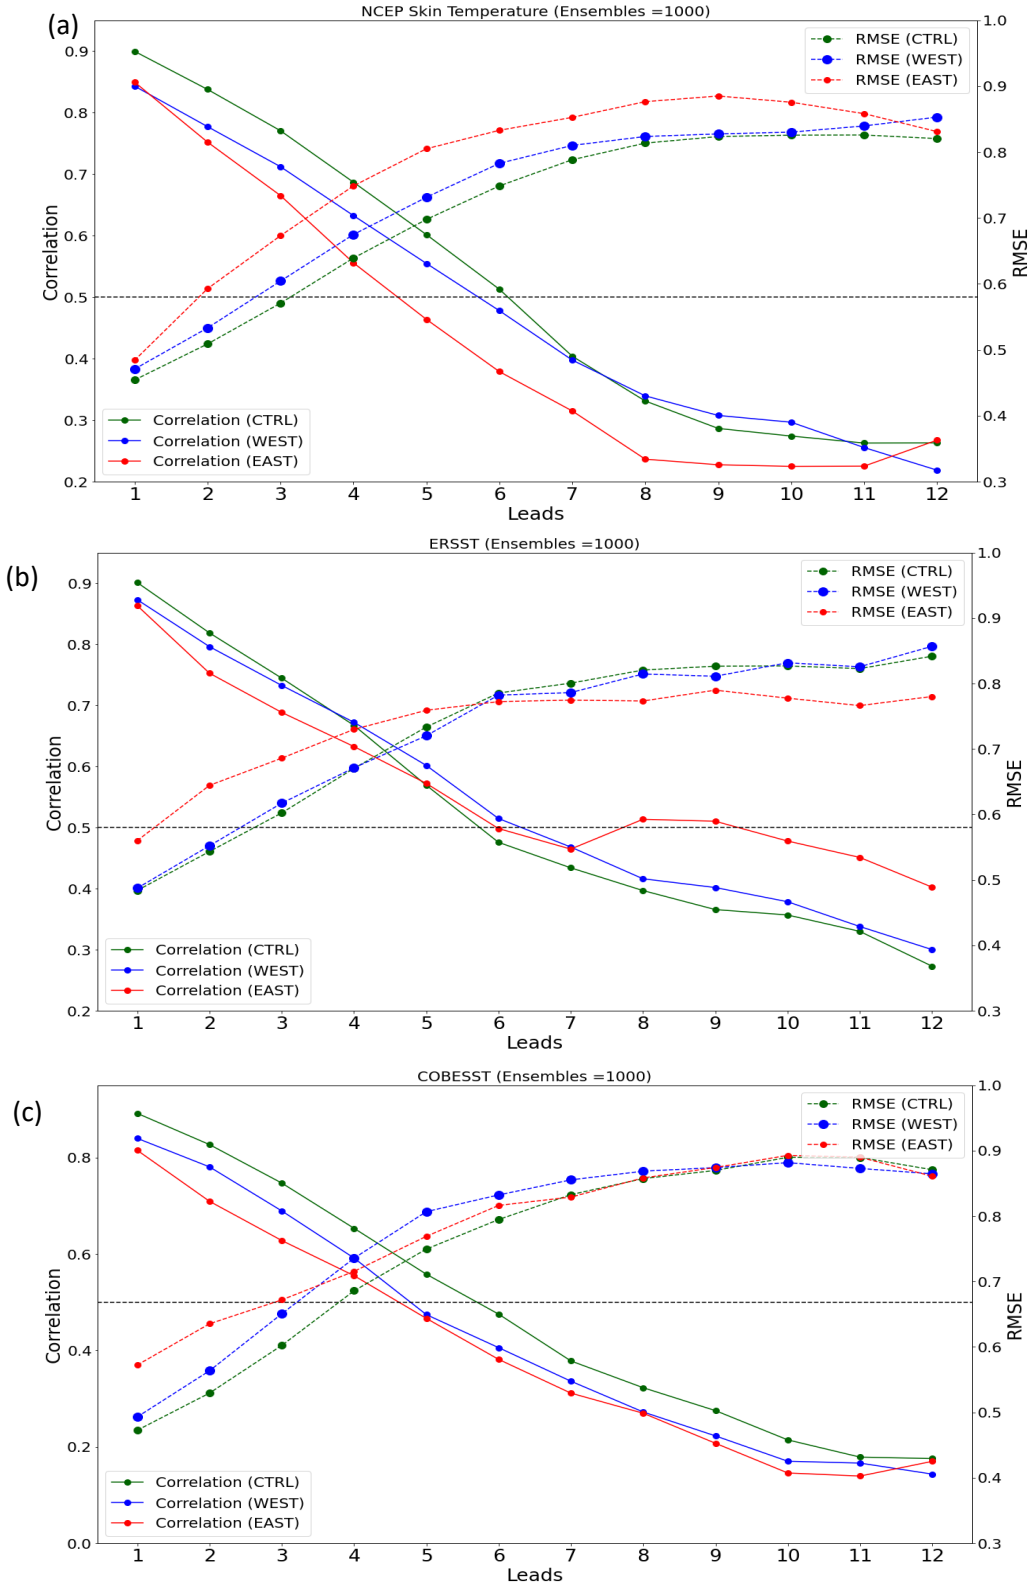


图11：比较使用不同海表温度数据训练的 CTRL、WEST 和 EAST 实验的相关系数和均方根误差，包括（a）美国国家环境预报中心皮肤温度（b）ERSST V5海表温度（c）COBE海表温度。比较采用了2002—2021年同一时期每组1000个集合的平均值。