arXiv:2602.02813v1 [stat.AP] 2 Feb 2026

利用边缘检测和分块对角高斯过程回归对地表温度数据进行降尺度*

Sanjit Dandapanthula† Margaret Johnson‡ Madeleine Pascolini-Campbell‡

Glynn Hulley‡ Mikael Kuusela†

2026年2月4日

摘要

准确、高分辨率地估算地表温度（LST），对于估算蒸散发至关重要。蒸散发是衡量植物用水量的指标，也是农业应用中的核心变量。本文提出一种新的统计方法，利用 Landsat 8任务获取的高分辨率数据作为农田结构的代理，对美国国家航空航天局 ECOSTRESS任务获取的地表温度数据进行降尺度。我们利用 Landsat 数据，通过边缘检测技术识别农田边界，从而捕捉空间域中固有的分块结构。我们提出一种分块对角高斯过程（BDGP）模型，以刻画农田的空间结构，利用各农田之间地表温度的独立性来提高计算效率，并考虑 ECOSTRESS 观测中存在的支撑域变化。我们利用所得 BDGP 模型执行高斯过程回归，从 ECOSTRESS 数据中获得高分辨率地表温度估计，并量化其不确定性。结果表明，所提出的方法能够切实有效地生成可靠的高分辨率地表温度估计，并有望应用于农业、城市规划和气候研究。

1 引言 **2**

2 方法 **4**

2.1 边缘检测 .5 2.2 傅里叶回归 .6 2.3 参数估计 .6 2.4 克里金法与不确定性量化 .7

†卡内基梅隆大学，统计学系（电子邮箱：sanjitd@cmu.edu）

‡喷气推进实验室，加利福尼亚理工学院

*本研究部分工作是在与美国国家航空航天局（80NM0018D0004）的合同框架下，于加利福尼亚理工学院喷气推进实验室开展的。

3 结果 8 4 讨论 11 A ECOSTRESS 方差参数的估计 13 B 补充图 14 C 方法验证 14 D 细化过度分割的图像 15

1 引言

利用遥感卫星观测数据获取高分辨率地表温度（LST）估计值，是环境统计学中的一个重要问题；例如，准确估计地表温度对于理解蒸散发 （ET）至关重要，而蒸散发是地球水循环中的一个核心量（Fisher 等，2017）。空间建模也用于这一领域，以填补观测数据之间的缺口，但本文不关注这一应用。目前构建地表温度数据统计模型的尝试，尚无法充分考虑数据复杂的空间结构，尤其是在农田周边，而这些区域的地表温度估计最为关键。传统空间模型（如平稳高斯过程）无法捕捉农田边界处地表温度的突变，从而可能导致过度平滑和预测不准确。因此，需要更先进的统计方法，以有效刻画地表温度数据中的空间结构。

ET 是从地球陆地表面向大气传输的蒸发和植物蒸腾之和（Fisher 等，2017）。它是水循环的关键组成部分，也是研究气候变化、农业和水资源管理的重要变量。ET 受多种因素影响，包括地表温度、太阳辐射、风速和湿度。具体而言，地表温度是影响 ET 的关键因素，因为它决定了可用于蒸发和蒸腾的能量总量。因此，准确估计地表温度对于预测 ET 至关重要。

空间站生态系统太空热辐射计实验（ECOSTRESS）辐射计于2018年6月部署在国际空间站（ISS）上，使用红外传感器测量地表温度和发射率（Fisher 等人，2020年）。过境重访频率，或称重访率，是指传感器经过地球上某一特定位置的频率。ECOSTRESS任务的过境重访频率可变（1至5天），目前提供空间分辨率约为70米的最高分辨率星载地表温度估计。然而，研究表明，ECOSTRESS地表温度图像的实际有效分辨率显著较低（Holmes 等人，2024年），这可能是由于传感器受损造成的模糊和伪影。

Landsat计划 m是一系列由美国国家航空航天局共同管理的地球观测卫星任务，和 d

美国地质调查局（USGS），自1972年以来一直提供地球表面的高分辨率影像（Roy et al., 2014年）。Landsat 卫星配备了可在多个光谱波段采集数据的传感器，包括可见光、近红外和热红外，从而能够对土地覆盖、植被健康状况和地表温度进行详细分析。陆地卫星 8/9 的仪器以高于 ECOSTRESS 的分辨率（30米）提供可见光至短波红外（VSWIR）数据，但过境重访频率较低（16天）。陆地卫星 8/9 热红外传感器（TIRS）的热红外波段少于 ECOSTRESS，因此地表温度估计的保真度可能较低，且标称空间分辨率也较低（100米）。

在我们的研究中，我们利用空间分辨率更高的陆地卫星 8/9 可见光至短波红外数据，作为模型化 ECOSTRESS 地表温度数据中农田结构的代理变量。这项任务通常称为 数据融合，在遥感领域受到广泛关注，其应用场景远不止地表温度数据（Khaleghi 等，2013 年；Samadzadegan 等，2025年）。我们在图 1中展示了来自这两项任务的示例图像，反映了本研究关注的农田结构类型。请注意，ECOSTRESS 和 Landsat 图像的单位不同，采集时间也不相同；此图仅用于说明空间分辨率的差异。

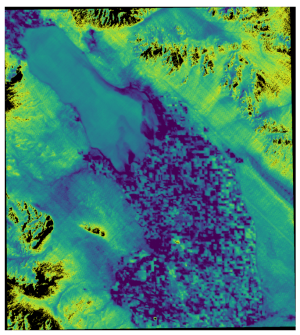

(a) ECOSTRESS（分辨率为 70 米）

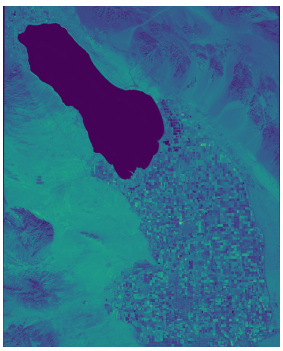

(b) Landsat（分辨率为 30 米）

图 1：南加利福尼亚索尔顿海地区 ECOSTRESS 与 Landsat 任务影像分辨率对比。

长期以来，研究者一直致力于探索地表温度数据的降尺度方法，即采用随机森林回归，直接对高分辨率图像及其低分辨率对应图像进行回归（Njuki 等，2020年；Hutengs 和 Vohland，2016 年；Li 等，2018年）以及神经网络（Wu 等，2022年；Li 等，2025年；Bindhu 等，2013年）。相比之下，我们采用高斯过程回归的统计方法在这方面尚属新颖。我们的方法有几个主要优势：底层统计模型更易解释，建模假设较弱（可能因此更稳健），并且能够以规范的方式量化重建结果的不确定性。

与我们的方法更为相似的是，Garrigues 等人（2007）提出了适用于块结构空间数据的镶嵌过程模型，该模型允许空间域的不同区域具有不同的协方差结构。然而，该模型的复杂性使其难以扩展到更大的数据集，例如遥感应用中遇到的数据集。该模型还仅适用于边界由

贯穿空间域的直线构成的块，因此不适合对形状不规则的农田进行建模。此外，镶嵌过程模型中的镶嵌剖分是随机的，这可能导致其在空间制图中的约束不足。

本文的主要贡献如下：

- 我们提出了一种新颖的统计方法，利用Landsat任务获取的高分辨率数据作为农田结构建模的代理数据，对ECOSTRESS任务的地表温度数据进行降尺度。

- 我们开发了一种分块对角高斯过程（BDGP）模型，该模型能够捕捉农田的空间结构，并利用不同农田之间地表温度的独立性，以实现计算上的可行性。

- 我们展示了所提出方法在生成高分辨率地表温度估计结果及进行不确定性量化方面的实用性。

我们在第2节概述了方法；边缘检测方法见第2.1节，用于建模均值函数的傅里叶回归方法见第2.2节，参数估计过程见第2.3节，克里金法和不确定性量化方法见第2.4节。我们在第3节展示结果，并在第4节进行讨论总结。

2 方法

使用高斯过程（GP）对空间数据进行建模是一种常见做法（Gelfand 等，2010）。为了考虑地表温度数据中存在的农田结构，我们使用带有平方指数核的分块对角高斯过程对地表温度进行建模。假设我们将 $\mathcal{X}$ 划分为 N 个区域，划分为 $\mathcal{R} := \{R_1, \ldots, R_N\}$。给定方差参数 $\boldsymbol{\ell} := (\ell_1, \ldots, \ell_N) \in (0, \infty)^N$ 和长度尺度参数 $\boldsymbol{\sigma} := (\sigma_1, \ldots, \sigma_N) \in (0, \infty)^N$，我们将参数为 $(\boldsymbol{\sigma}, \boldsymbol{\ell})$ 的分块对角平方指数协方差核定义为 $k(x, x') = \sum_{r=1}^{N} k_r(x, x')$，其中：

$$k_r(x, x') = \begin{cases} \sigma_r^2 \exp\left(-\|x - x'\|_2^2 / (2\ell_r^2)\right), & x, x' \in R_r \\ 0, & \text{otherwise.} \end{cases}$$

该核在每个区域内都是平稳的。给定任意均值函数 $\mu\colon \mathcal{X} \to \mathbb{R}$，我们称具有参数 $(\mu, \boldsymbol{\sigma}, \boldsymbol{\ell}, \mathcal{R})$（记为 BDGP$(\mu, \boldsymbol{\sigma}, \boldsymbol{\ell}, \mathcal{R})$）的分块对角高斯过程为一个高斯过程，其均值函数为 μ，协方差核为 k，形式如上。

我们假设，在给定时刻，潜在的 LST场是一个 BDGP $f^{\mathrm{ES}} := \mathrm{BDGP}(\mu^{\mathrm{ES}}, \sigma^{\mathrm{ES}}, \ell^{\mathrm{ES}}, \mathcal{R})$，并且观测到模糊的 $\tilde{f}^{\mathrm{ES}} := (f^{\mathrm{ES}} * \kappa_{\mathrm{blur}}) + f_{\mathrm{sensor}}$ 的样本，其中 $*$ 表示二维卷积。这里，κ_{blur} 是 $\mathcal{N}(0, \sigma_{\mathrm{blur}}^2 I)$ 的概率密度（用于考虑 ECOSTRESS 有限分辨率导致的支撑集变化），而 $f_{\mathrm{sensor}} \sim \mathcal{N}(0, \sigma_{\mathrm{sensor}}^2 I)$ 则用于表示 ECOSTRESS 中的传感器噪声。我们进一步假设，Landsat 数据由 $f^{\mathrm{LS}} := \mathrm{BDGP}(\mu^{\mathrm{LS}}, \sigma^{\mathrm{LS}}, \ell^{\mathrm{LS}}, \mathcal{R})$ 生成。为确保该模型中的参数可辨识，我们作出简化假设：$\ell^{\mathrm{ES}} = \ell^{\mathrm{LS}}$。

接下来，我们将 LST 降尺度流程概述如下：

(1) 边缘检测：对平均后的高分辨率 Landsat 图像应用边缘检测方法，识别不同农田之间的边界，从而估计划分 $\mathcal{R}$。

(2) 参数估计：固定 $\mathcal{R}$，通过最大似然估计，利用 Landsat 数据和 ECOSTRESS 数据拟合 BDGP 模型的其余参数。

(3) 克里金法与不确定性量化：使用拟合后的 ECOSTRESS BDGP 模型进行克里金法处理，获得地表温度残差场的高分辨率预测（$f_{\mathrm{ES}} - \mathbb{E}[f^{\mathrm{ES}}]$），并量化不确定性。

我们的降尺度流程概述如图 2所示。

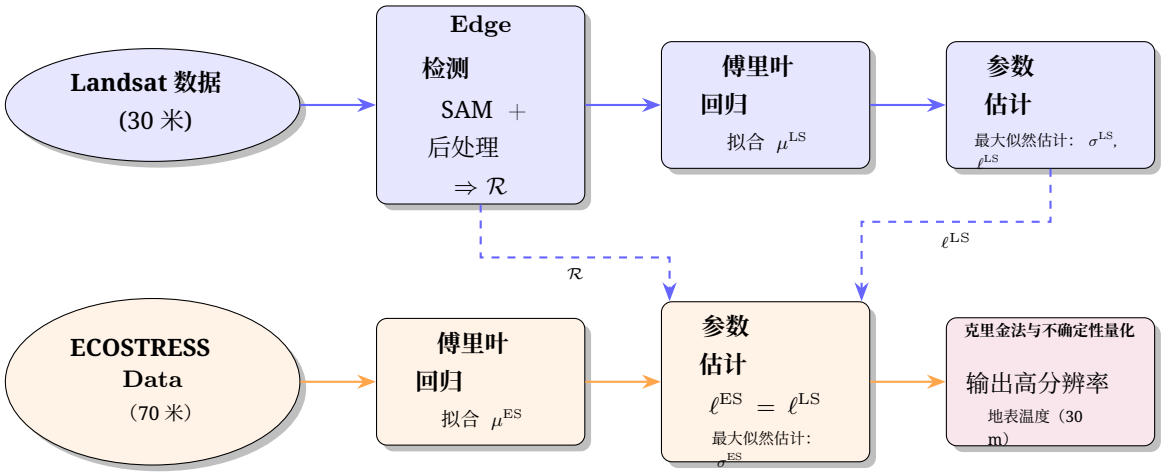

图 2：所提出的降尺度流程概览。所提出的降尺度流程概览。Landsat 数据以蓝色显示，ECOSTRESS 数据以橙色显示，算法的输出以紫色显示。

2.1 边缘检测

首先，我们对 6 幅独立的高分辨率 Landsat 图像取平均，并在平均图像上使用边缘检测方法，以识别不同农田之间的边界。在我们的案例中，我们使用 Meta 的 Segment Anything Model (SAM)。这是一种先进的、基于视觉变换器 (ViT) 的分割模型，可对输入图像进行过分割——模型可能会生成部分或完全重叠的分割区域（Kirillov 等，2023）。我们还尝试了其他几种方法，包括 Canny、Sobel 和拉普拉斯边缘检测算法，但发现 SAM 在实际应用中效果最佳。接下来，我们按照附录D中介绍的算法对过分割图像进行后处理，将重叠区域合并。此后处理步骤可确保最终的分割区域集合中不存在重叠。至此，我们得到了空间域划分的估计结果 $\mathcal{R}$，将空间域划分为农田。

2.2 傅里叶回归

接下来，我们使用年频率的傅里叶回归，为每个像素 $x = (i, j)$ 分别拟合 μ^{LS}：

$$\mu_{ij}^{\mathrm{LS}}(t) = (\beta_0)_{ij} + (\beta_1)_{ij}\cos(2\pi t/365) + (\beta_2)_{ij}\sin(2\pi t/365),$$

其中 t 以天为单位。我们使用普通最小二乘法拟合系数。这里仅使用年频率，因为 Landsat 卫星采用太阳同步 轨道，这意味着卫星每隔 16 天便会在一天中的同一时间经过地球上的同一地点。因此，我们无法对这些数据的日频率进行建模。接下来，我们使用具有年频率和日频率的傅里叶回归，对每个像素 (i, j) 分别拟合模糊均值 $\mu^{\mathrm{ES}} * \kappa_{\mathrm{blur}}$：

$$\begin{aligned}&(\mu^{\mathrm{ES}} * \kappa_{\mathrm{blur}})_{ij}(t)\\ &\quad= (\beta_0)_{ij} + (\beta_1)_{ij}\cos(2\pi t/365) + (\beta_2)_{ij}\sin(2\pi t/365) + (\beta_3)_{ij}\cos(2\pi t) + (\beta_4)_{ij}\sin(2\pi t)\end{aligned}$$

其中 t 以天为单位。请注意，我们在此拟合的是模糊均值函数，因为我们只能观测到来自 ECOSTRESS 的模糊数据。最后，我们从观测数据中减去拟合的均值函数，以便用零均值高斯过程对残差数据进行建模。从 图 7 (附录 B) 可以看出，单个傅里叶项足以捕捉数据中的年周期和日周期，因此我们可以使用均值为零的 BDGP 对残差进行建模。同样，我们在 图 8 (附录 B) 中展示了 Landsat 数据中随机像素的年周期拟合结果。拟合的周期大致捕捉了地表温度的季节性变化，这证明使用傅里叶回归对均值函数进行建模是合理的。

2.3 参数估计

鉴于 ECOSTRESS 观测数据所列的不确定性均约为 0.1 开尔文，因此选择 $\sigma_{\mathrm{sensor}} = 0.1$是合理的。根据（Holmes 等人，2024年），我们知道 ECOSTRESS 的点扩散函数在各个方向上的半峰全宽（FWHM）约为 160 米，大约是名义像素尺寸 70 米的两倍。根据半峰全宽，我们可以通过 $\sigma_{\mathrm{blur}} = (160/70)/(2\sqrt{2\ln(2)}) \approx 0.97$ 计算标准差，单位为 ECOSTRESS 像素。维基百科贡献者（2025年）对此计算作了说明。

固定 $\mathcal{R}$ 后，我们现在将 BDGP 模型的其余参数拟合到 Landsat 数据。这里，每个区域都可以独立拟合，因此易于并行处理，也便于扩展到更大的数据集。这里我们不在协方差结构中加入时间分量，而是选择时间间隔较远的样本，以降低时间相关性。因此，我们可以将这些点视为在时间上相互独立。我们选取 4 个采样日期 t_1、t_2、t_3、t_4，彼此间隔约三个月。假设区域 R_r 中的观测值在时间上相互独立，我们将观测数据的似然写为：

$$\mathcal{L}(\sigma_r^{\mathrm{LS}}, \ell_r^{\mathrm{LS}}; y) = \prod_{i=1}^{4} f_{\mathcal{N}(0, K_{R_r})}(y_{R_r, t_i}^{\mathrm{LS}}),$$

其中， K_{R_r} 是限制在区域 r 内的 BDGP 协方差矩阵，$y^{\mathrm{LS}}_{R_r,\, t_i}$ 是区域 R_r 在时间 t_i 的观测残差。我们通过使用 BFGS优化器最大化该似然来估计参数，并在协方差矩阵中加入一个较小的块金项 $10^{-8}I$，以确保数值稳定性。

接下来，我们固定 $\mathcal{R}$ 并假设 $\ell^{\mathrm{ES}} = \ell^{\mathrm{LS}}$。尽管 Landsat 和 ECOSTRESS 数据测量的是不同量，但由于它们覆盖同一地理区域，且具有相似的空间变化，因此可以合理地认为，两个数据集的残差场尺度参数应当相近。ECOSTRESS 数据中的支撑域变化会导致不适定性，因此这一假设是确保模型参数可识别性所必需的。然后，我们通过最大似然估计将 σ^{ES} 拟合到 ECOSTRESS 数据。

现在，我们忽略各区域边缘处来自其他区域的模糊影响，并对每个区域分别进行拟合；这是合理的，因为与区域相比，模糊核的相对尺度较小。在这一简化假设下，基于单次观测的相合估计量为

$$(\hat{\sigma}^{\mathrm{ES}}_r)^2 = (\widehat{\mathrm{Var}}(y^{\mathrm{ES}}_{R_r}) - \sigma^2_{\mathrm{sensor}}) \left(\frac{(\ell^{\mathrm{ES}}_r)^2 + \sigma^2_{\mathrm{blur}}}{(\ell^{\mathrm{ES}}_r)^2} \right). \tag{1}$$

这里，我们用 $\mathrm{Var}(y^{\mathrm{ES}}_{R_r})$ 表示区域 R_r内观测残差的样本方差，并在 附录A中说明采用该估计量的理由。然后，我们通过计算各时间点估计值的中位数，对每个独立时间点的 σ^{ES}_r估计值进行汇总。

2.4 克里金法与不确定性量化

最后，我们使用为 ECOSTRESS 拟合的 BDGP 模型进行克里金法（在 30 m 网格上），从而获得地表温度残差场的高分辨率预测。尽管各区域在模糊之后不再相互独立，但在考虑每个区域 R_r周围的 $4\sigma_{\mathrm{blur}}$像素邻域 R'_r 后，我们仍可独立处理每个区域。首先，将像素枚举为 $x_1, \ldots, x_P$，并将 k_* 定义为$f(x_*)$与 R'_r 中所有模糊观测之间的协方差向量：

$$(k_*)_i = \mathrm{Cov}(f^{\mathrm{ES}}(x_*),\, \tilde{f}^{\mathrm{ES}}(x_i)) = (k(x_*, \cdot) * \kappa_{\mathrm{blur}}(\cdot))(x_i).$$

接下来，令 $K_{R'_r}$ 为限制在区域 R'_r上的 BDGP 的协方差矩阵：

$$(K_{R'_r})_{ij} = \mathrm{Cov}(\tilde{f}^{\mathrm{ES}}(x_i),\, \tilde{f}^{\mathrm{ES}}(x_j)) = \iint \kappa_{\mathrm{blur}}(x_i - u)\, \kappa_{\mathrm{blur}}(x_j - v)\, k(u, v)\, du\, dv.$$

最后，令 $y^{\mathrm{ES}}_{R'_r}$为区域 R'_r中的观测残差；即，$(y^{\mathrm{ES}}_{R'_r})_i = \tilde{f}^{\mathrm{ES}}(x_i)$ 对于 $x_i \in R'_r$。采用该记号，克里金法公式（Cressie, 1991）给出区域 R_r 中位置 x_* 处的条件均值为

$$\hat{f}^{\mathrm{ES}}_{R_r}(x_*) = k_*^{\top} (K_{R'_r} + \sigma^2_{\mathrm{sensor}} I)^{-1} y^{\mathrm{ES}}_{R'_r}.$$

对每个区域重复此计算 R_r，即可得到完整的克里金预测 $\hat{}f^{\mathrm{ES}}$。通过分别重建各个区域，只要每个区域不太大，我们就能并行执行这一步，并保持计算上的可行性。在本研究中，我们不重建道路区域，因为使用当前实现高效重建该区域所需的规模过大。虽然可以重建道路

区域，将其划分为若干个相互重叠的子区域，但道路并非农业应用的主要关注对象，因此我们将此留待未来工作。此外，由于我们仍会估计道路区域的参数，这不会影响其他区域的重建结果。

接下来，为计算区域 R_r内位置 x_* 处克里金预测的方差，我们使用如下公式

$$\mathrm{Var}(\hat{f}^{\mathrm{ES}}(x_*)) = \mathrm{Var}(f^{\mathrm{ES}}(x_*)) - k_*^\top (K_{R_r'} + \sigma^2_{\mathrm{sensor}} I)^{-1} k_*.$$

例如，该公式可见于 Cressie (1991)。请注意，所得重建仅为残差场；要获得完整的LST场，我们需要加回反卷积均值函数，这可以借助空间统计学方法更细致地完成。不过，我们将此留待未来工作。

3 结果

在我们的分析中，我们考虑一块面积为6 km^2 、位于南加利福尼亚（美国）索尔顿海附近的农业区域。我们使用Landsat 8卫星的SR_B5通道数据（Roy等人，2014年），该通道测量近红外光谱中的地表反射率。我们的目标是以Landsat数据作为模拟农田结构的代理，对2021年1月获取的ECOSTRESS（Fisher等人，2020年）LST图像进行反卷积。我们将两个数据集预处理到分辨率为30 m的公共网格上。在全部分析中，我们人工选取感兴趣区域内相对无云的图像，并且不考虑缺失。当存在少量缺失数据时，我们所有的参数估计和克里金法程序只需对代码稍作修改即可适用。同样，大量缺失可通过在高斯过程中加入时间分量来处理，但这留待未来工作。

首先，我们展示感兴趣区域内 6 幅 Landsat 图像（自 2021 年 11 月起采集，间隔约两个月）的平均图像上应用边缘检测方法的结果，见图 3。因此，我们确认最终划分的区域较好地反映了农田结构，并且后处理后不同区域之间没有重叠。

接下来，我们在图 4a中展示 2021 年 1 月的原始 ECOSTRESS 图像（我们希望对其进行去模糊处理），以及在图 4b中展示减去拟合均值函数后得到的残差。正如预期，残差包含显著的空间结构，我们可以使用 BDGP方法对其建模。当天气温特别低，因此图像的大部分区域都呈现负残差。为验证我们的均值函数对 Landsat 数据是否合理，我们还在图 4d中展示了一幅 Landsat 样本图像的残差。同样，我们看到残差包含显著的空间结构，可以使用 BDGP方法对其建模，并且残差接近于零。

接下来，我们展示图5中各区域的拟合参数。为估计这些参数，我们使用了2020年到2021年间的4幅 ECOSTRESS 图像（不包括目标图像），时间间隔约为3个月。同样，我们使用了从2021年11月开始、间隔约为3



(a) 平均 Landsat 图像　　(b) SAM 过分割　　(c) 后处理后的区域

图 3：并排比较 (a) 平均 Landsat 图像、(b) SAM 生成的过分割图像，以及 (c) 后处理后的最终区域。

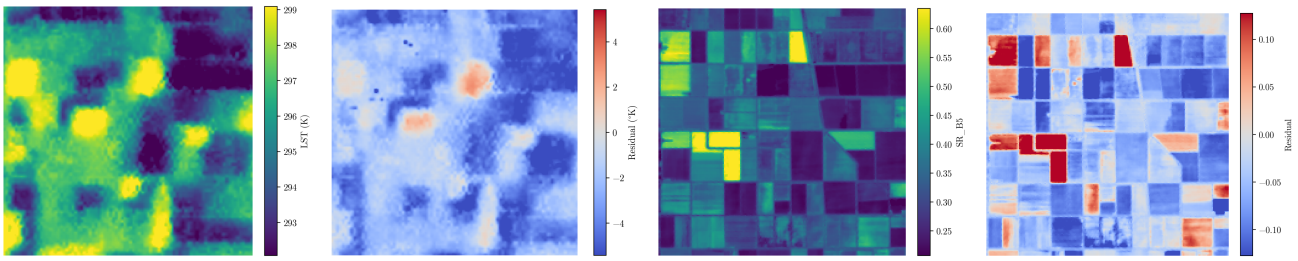

(a)ECOSTRESS 原始图像 (b)ECOSTRESS 残差　　(c) Landsat 原始图像　　(d) Landsat 残差

图 4：并排比较 (a) 原始 ECOSTRESS 图像、(b) 减去拟合均值函数后的 ECOSTRESS 残差、(c) 原始 Landsat 图像，以及 (d) 减去拟合均值函数后的 Landsat 残差。

每月。我们可以看到，各区域的长度尺度差异显著，这证明采用分块对角高斯过程来建模农田结构是合理的。此外，优化过程似乎为两个数据集都找到了合理的参数值。最后，我们在图6中展示克里金结果及相应的不确定性量化。克里金预测有效地消除了原始 ECOSTRESS 图像中许多特征的模糊，我们还可以通过逐像素方差量化预测的不确定性。请注意，每个区域边缘附近的不确定性较高；这是因为区域间相互独立的统计假设增加了边缘附近重建的不确定性。

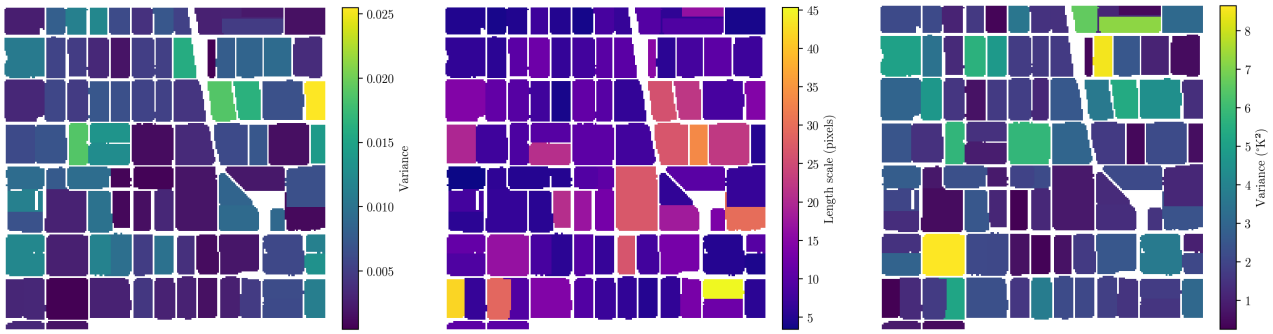

(a) Landsat 各区域方差　　(b) 各区域长度尺度　　(c) ECOSTRESS 各区域方差

图5：各区域的拟合参数：(a) Landsat 各区域方差，(b) 各区域长度尺度（Landsat 和 ECOSTRESS 共用），以及 (c) ECOSTRESS 各区域方差。

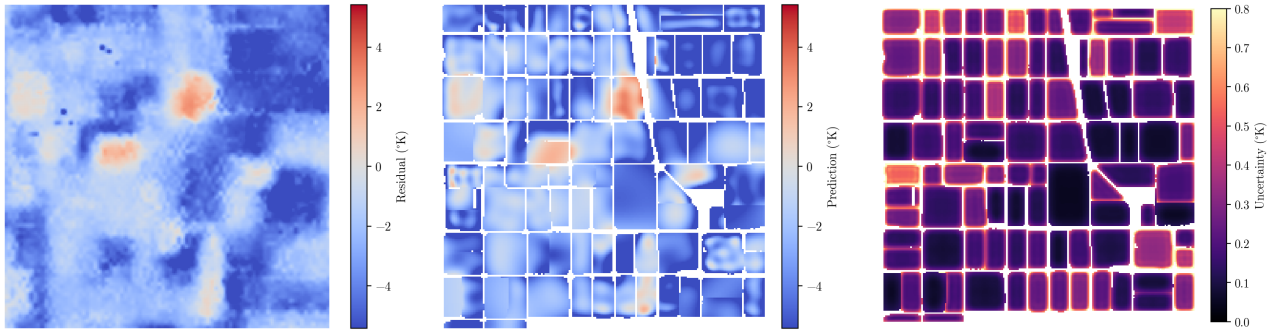

(a) 原始 ECOSTRESS 残差　　(b) 克里金均值预测　　(c) 克里金逐像素 2σ

图6：比较 (a) 原始 ECOSTRESS 残差图像、(b) 克里金均值预测，以及 (c) 克里金预测的两个逐像素标准差。

我们通过在附录C中手动模糊并复原一幅高分辨率 Landsat 图像，验证了我们的方法效果良好。

4 讨论

在本研究中，我们提出了一种新颖的统计方法，利用 Landsat任务的高分辨率数据作为农田结构的建模代理，对 ECOSTRESS任务的地表温度数据进行降尺度。借助分块对角高斯过程模型，我们能够捕捉农田的空间结构，并进行可扩展推断。结果表明，所提出的方法能够有效去除 ECOSTRESS地表温度数据的模糊，生成更高分辨率的估计结果，并量化不确定性。不同区域的拟合参数差异显著，这证明了采用分块对角高斯过程对农田结构进行建模的合理性。此外，我们的玩具示例验证了该方法能够成功重建模糊图像，复原原始数据中存在的特征。

尽管我们提出的框架具有诸多优势，但仍存在若干局限。首先，虽然我们估计了农田之间道路网络的参数，但由于该区域规模较大，本研究未对其进行重建。其次，尽管采用 Segment Anything Model (SAM) 的分割方法表现出色，未来研究仍可考虑采用其他分割算法，或将分割的不确定性纳入考量。此外，我们方法的性能本质上受 ECOSTRESS 数据质量的限制；该数据因传感器物理损坏而存在模糊和伪影。我们的模糊核和加性传感器噪声服从高斯分布这一假设同样受到影响；鉴于Holmes 等人 (2024)指出 ECOSTRESS点扩散函数并非完全符合高斯分布，这些假设可能并不精确。最后，为确保可识别性，我们采用了简化假设，即 ECOSTRESS 与 Landsat 的长度尺度参数相同；这一条件在实际中未必严格成立。

未来工作中，可在分块对角高斯过程（BDGP）核中加入时间长度尺度，以捕捉时变动态。这样便可进行时间上的缺口填补；考虑到缺失数据量很大，这在实践中具有重要价值。此外，用更尖锐的Matérn核替代标准平方指数核，或许能更准确地刻画地表温度场的粗糙度。从计算角度看，进一步优化代码将有助于扩展至更大的数据集。另一个未来方向是对高分辨率地表温度场的均值进行建模，或许可以利用辅助的（更高分辨率）数据源。最后，可以将道路划分为更小、更易处理的区域，以便也能对这些区域进行重建。

这项工作更广泛的意义在于，通过使用块对角高斯过程对场结构进行建模，我们获得了一套用于构建可扩展统计模型的处理流程，以融合具有互补优势的传感器数据。该方法同时考虑了数据中存在的支撑域变化和场结构，使我们能够对大型数据集进行可扩展的统计建模。例如，该方法可应用于城市热岛建模、欧洲农业景观（田块形状更不规则），或其他可获得高分辨率代理数据的遥感场景。

数据可用性

代码见https://github.com/sanjitdp/downscaling-lst。复现数据可从 https://appeears.earthdatacloud.nasa.gov/ 使用 `.json` 代码库中包含的请求文件获取。

参考文献

Bindhu, V., Narasimhan, B., & Sudheer, K. (2013). 开发并验证一种非线性解聚方法（NL-DisTrad），用于将中分辨率成像光谱仪地表温度降尺度至 Landsat 热红外数据的空间尺度，以估算蒸散发。《环境遥感》, *135*, 118–129.

Cressie, N. (1991). 空间数据统计学. 约翰·威立父子公司.

Fisher, J. B., Lee, B., Purdy, A. J., Halverson, G. H., Dohlen, M. B., Cawse-Nicholson, K., Wang, A., Anderson, R. G., Aragon, B., Arain, M. A., Baldocchi, D. D., Baker, J. M., Barral, H., Bernac- chi, C. J., Bernhofer, C., Biraud, S. C., Bohrer, G., Brunsell, N., Cappelaere, B., .. . Hook, S. (2020年). ECOSTRESS：美国国家航空航天局的新一代任务，旨在从国际空间站测量蒸散发。《水资源研究》, *56*(4).

Fisher, J. B., Melton, F., Middleton, E., Hain, C., Anderson, M., Allen, R., McCabe, M. F., Hook, S., Baldocchi, D., Townsend, P. A., Kilic, A., Tu, K., Miralles, D. D., Perret, J., Lagouarde, J.-P., Waliser, D., Purdy, A. J., French, A., Schimel, D., . .. Wood, E. F. (2017). 蒸散发的未来：生态系统功能、碳与气候反馈、农业管理和水资源的全球需求。《水资源研究》, *53*(4), 2618–2626. Garrigues, S., Allard, D., & Baret, F. (2007). 利用一阶和二阶变异函数表征遥感影像中的景观空间结构。《*IEEE*地球科学与遥感汇刊》, *45*(6), 1823–1834. Gelfand, A. E., Diggle, P., Guttorp, P., & Fuentes, M. (2010). 空间统计学手册。CRC出版社。Holmes, T. R., Poulter, B., McCorkel, J., Jennings, D., Wu, D., Efremova, B., Shiklomanov, A., Johnson, W., Jhabvala, M., & Hook, S. (2024). 陆地卫星7号、8号和9号、ECOSTRESS及CTI热红外成像仪的在轨空间性能表征。《地球物理研究杂志：生物地球科学》, *129*(2). Hutengs, C., & Vohland, M. (2016). 利用随机森林回归在区域尺度上对地表温度进行降尺度。《环境遥感》, *178*, 127–141. Khaleghi, B., Khamis, A., Karray, F. O., & Razavi, S. N. (2013). 多传感器数据融合：最新进展综述。《信息融合》, *14*(1), 28–44. Kirillov, A., Mintun, E., Ravi, N., Mao, H., Rolland, C., Gustafson, L., Xiao, T., Whitehead, S., Berg, A. C., Lo, W.-Y., Dollár, P., & Girshick, R. (2023). 万物分割。*IEEE/CVF*国际计算机视觉会议论文集, 4015–4026.

Li, S., Wan, H., Yu, Q., & Wang, X. (2025). 基于注意力机制和Google Earth Engine对ERA5再分析地表温度进行降尺度。《科学报告》，*15*(1), 675. Li, W., Ni, L., Li, Z.-L., & Wu, H. (2018). 利用随机森林回归算法对地表温度进行降尺度。*IGARSS 2018-2018 IEEE*国际地球科学与遥感研讨会，2527–2530. Njuki, S. M., Mannaerts, C. M., & Su, Z. (2020). 通过减小随机森林中的空间平均偏差，改进粗分辨率热数据降尺度方法。遥感，*12*(21), 3507. Roy, D., Wulder, M., Loveland, T., C.E., W., Allen, R., Anderson, M., Helder, D., Irons, J., Johnson, D., Kennedy, R., Scambos, T., Schaaf, C., Schott, J., Sheng, Y., Vermote, E., Belward, A., Bind- schadler, R., Cohen, W., Gao, F., ... Zhu, Z. (2014). Landsat-8：陆地全球变化研究的科学与产品愿景。《环境遥感》，*145*，154–172. Samadzadegan, F., Toosi, A., & Dadrass Javan, F. (2025). 多传感器与多平台遥感数据融合方法的批判性综述：现状与展望。《国际遥感杂志》，*46*(3), 1327–1402.Stoica,P., & Moses, R.L.(2005).信号谱分析 (第452卷)。Prentice Hall。维基百科贡献者。(2025)。https://en.wikipedia.org/wiki/Full_宽度_处_半_最大值 Wu, J., Xia, L., Chan, T. O., Awange, J., & Zhong, B. (2022). 地表温度降尺度：一种基于时空融合缩放因子的地理和时间神经网络加权自回归模型框架。《*ISPRS*摄影测量与遥感杂志》，*187*，259–272。

A 估计 ECOSTRESS 方差参数

在本节中，我们通过初等傅里叶分析（例如，1）论证 Stoica 和 Moses，2005年）。假设边缘处没有模糊，我们可以计算 f 的功率谱密度（PSD）：$= f_{R_r}^{\mathrm{ES}}$为

$$S_f(\omega) = A \exp(-4\pi^2 (\ell_r^{\mathrm{ES}})^2 \, \|\omega\|^2)$$

对于某个常数 $A > 0$。类似地，我们可以计算模糊核κ:= κ_{blur} 的能量谱密度:

$$|\hat{\kappa}(\omega)|^2 = \exp(-4\pi^2 \sigma_{\mathrm{blur}}^2 \|\omega\|^2),$$

其中，$\hat{}\kappa$ 表示 κ的傅里叶变换。卷积的功率谱密度可分解为乘积，因此我们得到

$$S_{f*\kappa}(\omega) = S_f(\omega) \, |\hat{\kappa}(\omega)|^2 = A \exp\left(-4\pi^2 \left((\ell_r^{\mathrm{ES}})^2 + \sigma_{\mathrm{blur}}^2\right) \|\omega\|^2\right).$$

特别是，对所有频率上的功率谱密度进行积分，可得到方差：

$$\begin{aligned}\mathrm{Var}(f * \kappa) &= \iint S_{f*\kappa}(\omega)\, d\omega \\ &= \iint A \exp\left(-4\pi^2 \left((\ell_r^{\mathrm{ES}})^2 + \sigma_{\mathrm{blur}}^2\right) \|\omega\|^2\right)\, d\omega \\ &= \frac{A}{4\pi\left((\ell_r^{\mathrm{ES}})^2 + \sigma_{\mathrm{blur}}^2\right)}.\end{aligned}$$

类似地，我们有

$$(\sigma_r^{\mathrm{ES}})^2 := \mathrm{Var}(f) = \iint S_f(\omega)\, d\omega = \iint A \exp(-4\pi^2 (\ell_r^{\mathrm{ES}})^2 \|\omega\|^2)\, d\omega = \frac{A}{4\pi(\ell_r^{\mathrm{ES}})^2}.$$

注意，由于（模糊）信号与传感器噪声相互独立，$\mathrm{Var}(y_{R_r}^{\mathrm{ES}}) = \mathrm{Var}(f * \kappa) + \sigma_{\mathrm{sensor}}^2$。综合以上各项，可得

$$\begin{aligned}(\sigma_r^{\mathrm{ES}})^2 &= \mathrm{Var}(f * \kappa) \left(\frac{(\ell_r^{\mathrm{ES}})^2 + \sigma_{\mathrm{blur}}^2}{(\ell_r^{\mathrm{ES}})^2}\right) \\ &= (\mathrm{Var}(y_{R_r}^{\mathrm{ES}}) - \sigma_{\mathrm{sensor}}^2) \left(\frac{(\ell_r^{\mathrm{ES}})^2 + \sigma_{\mathrm{blur}}^2}{(\ell_r^{\mathrm{ES}})^2}\right).\end{aligned}$$

最后，经验方差 $\widehat{\mathrm{Var}}(y_{R_r}^{\mathrm{ES}})$ 是 $\mathrm{Var}(y_{R_r}^{\mathrm{ES}})$ 的相合估计量，因为核是平方指数（因此是平稳且遍历的）。由此可知，所提出的 1 式中的估计量 σ_r^{ES}是一致的。

B 更多图示

本附录汇集了几幅补充图（图 7和 图 8）。

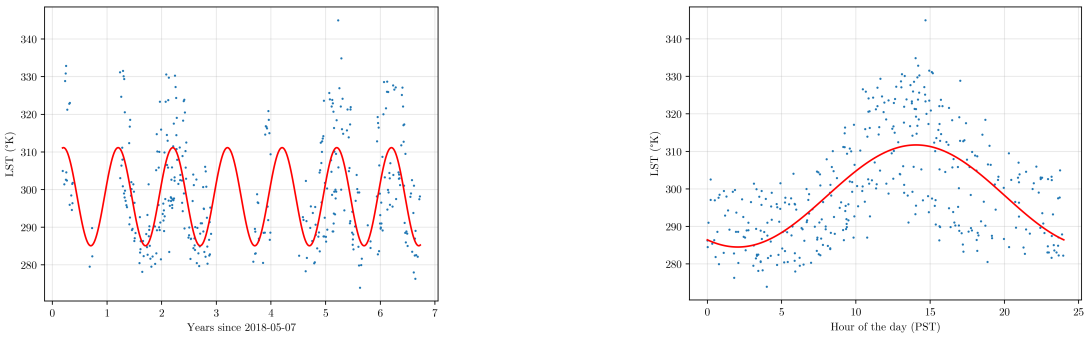

（a）年周期　　(b) 日周期

图 7：随机选取的像素处拟合温度周期的曲线图：(a) 基于 ECOSTRESS 数据的年周期，以及 (b) 基于 ECOSTRESS 数据的日周期。

C 方法验证

为验证我们的方法有效，我们最后手动对一幅高分辨率 Landsat 图像（图9）进行模糊处理。我们将 σ_{blur} 设为 0.97 个 ECOSTRESS 像素（70 米），这与我们发现 ECOSTRESS 数据集中存在的模糊程度相同

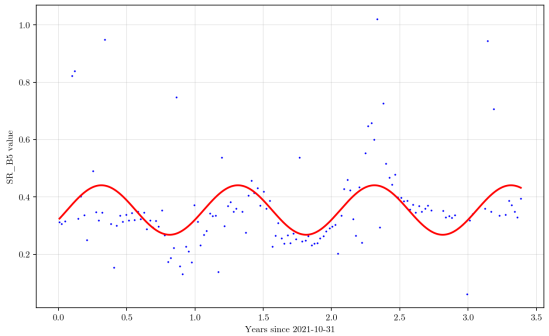

图 8：随机选取的一个像素处 Landsat 数据的 SR_B5 通道年周期图。该通道测量光线近红外光谱中的地表反射率。

。接着，我们将 $\sigma_{\text{sensor}} = 10^{-4}$设为一个合理的值，因为我们预计 Landsat 的传感器噪声远小于 ECOSTRESS。我们在这个玩具示例中使用了从真实数据估计出的相同参数。利用这些参数，我们通过简化版处理流程重建图像（图10）。请注意，克里金均值确实对图像进行了去模糊处理，恢复了原始图像中的部分特征。我们选择平方指数核，因此重建结果相对平滑；若使用不同的核，可以获得更粗糙的重建结果，但这留待未来工作。

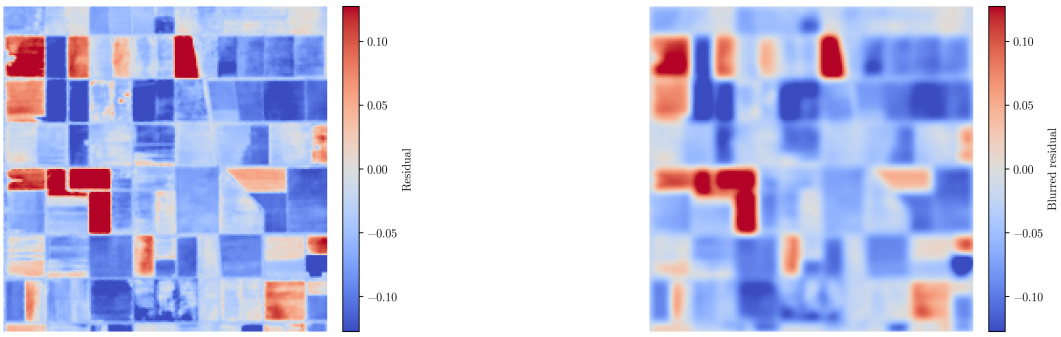

(a) 原始图像　　(b) 模糊图像

图9：(a) 原始高分辨率图像和 (b) 手动模糊后的图像，它们用作玩具示例的输入。

D 优化过度分割的图像

在本附录中，我们给出一种算法，用于优化 Segment Anything Model (SAM) 提供的过度分割图像。

- 丢弃所有少于 100 个像素的分割区域。
- 按面积递增的顺序排列剩余的分割区域。

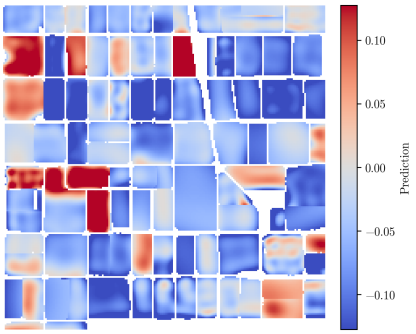

(a) 克里金均值

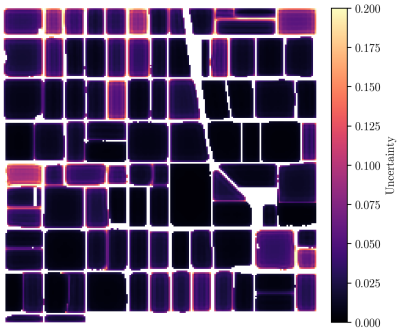

(b) 克里金逐像素 2σ

图10：在图 9的玩具示例上验证所提出的方法：(a) 克里金均值预测，以及 (b) 克里金预测的两个逐像素标准差。

- 按分割区域 s从大到小进行迭代：– 在所有之前保留的分割区域与 s 重叠的部分将其减去。– 将当前分割区域添加到保留分割区域列表中。