

基于贝叶斯岭回归的联合作战油料需求预测决策研究

方 玲, 陈如丽, 屈少辉*, 陈宇昕

联勤保障部队工程大学, 重庆

收稿日期: 2026年8月15日; 录用日期: 2026年9月7日; 发布日期: 2026年9月17日

摘 要

针对联合作战油料需求预测中不确定性量化不足、决策支持薄弱的问题, 本文提出一种基于贝叶斯岭回归的概率化预测与决策框架。该框架通过输出后验预测分布, 实现了对预测风险的科学量化; 进而将军事损失函数与后验分布相结合, 构建了可依据风险偏好调整的贝叶斯最优分位数决策模型。实例验证表明, 相较于岭回归, 所提框架在保持略优的点预测精度与更高稳定性的基础上, 提供了校准更佳的预测区间, 从而显著降低了决策的综合代价。研究为联合作战油料保障提供了集预测可靠性、不确定性透明化与决策适应性于一体的理论方法, 有助于推动保障模式从依赖点估计的经验决策, 向基于风险量化的主动优化转型。

关键词

油料需求预测, 贝叶斯岭回归, 不确定性量化, 后验分布, 决策优化

Research on Joint Operational POL Support Demand Forecasting and Decision-Making Based on Bayesian Ridge Regression

Ling Fang, Ruli Chen, Shaohui Qu*, Yuxin Chen

PLA Joint Logistics Support Force University of Engineering, Chongqing

Received: August 15, 2026; accepted: September 7, 2026; published: September 17, 2026

Abstract

Aiming at the problems of insufficient uncertainty quantification and weak decision support in joint

*通讯作者。

文章引用: 方玲, 陈如丽, 屈少辉, 陈宇昕. 基于贝叶斯岭回归的联合作战油料需求预测决策研究[J]. 统计学与应用, 2026, 15(9): 145-160. DOI: 10.12677/sa.2026.159214

operational POL support demand forecasting, this paper proposes a probabilistic forecasting and decision-making framework based on Bayesian Ridge Regression. The framework outputs a posterior predictive distribution to achieve scientific quantification of forecasting risk. Furthermore, by integrating a military loss function with the posterior distribution, it constructs a Bayesian optimal quantile decision model that can be adjusted according to risk preference. Case studies demonstrate that, compared with ridge regression, the proposed framework not only maintains slightly better point-forecast accuracy and higher stability, but also provides better-calibrated prediction intervals, thereby significantly reducing the integrated cost of decisions. This research offers an integrated theoretical and methodological support for joint operational POL support, combining forecasting reliability, uncertainty transparency, and decision adaptability, and helps to promote the shift of support mode from experience-based decision-making reliant on point estimates to proactive optimization based on risk quantification.

Keywords

POL Support Demand Forecasting, Bayesian Ridge Regression, Uncertainty Quantification, Posterior Distribution, Decision Optimization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

油料保障是联合作战后勤保障的重要活动，油料需求预测的准确性直接关系到资源调配的效能与作战任务的成败。实现油料精确保障，对于避免资源短缺或浪费、提升后勤保障效能具有不可替代的战略意义。因此，对油料需求进行科学预测，已成为优化后勤资源配置、提升整体作战效能的重要军事运筹问题。

围绕这一课题，国内外学者开展了大量研究。杨晓峰[1]等探讨了大数据技术在军用油料保障中的应用前景，提供了方向性思考；李忠国[2]等围绕军事斗争准备，总结了基于任务的油料需求计算方法；樊荣[3]与陆思锡[4]等分别将支持向量机应用于航空兵与舰艇部队的油料需求预测；吴书金[5] [6]等通过融合模糊聚类与灰色理论，构建了适用于合成旅多油品需求的模糊推理预测模型；周庆忠[7]等利用微粒群算法改进神经网络进行油料储备预测；陆思锡[8]和夏秀峰[9]等将灰色理论与神经网络相结合改进油料需求预测方法；龚杰[10]与周伟祝[11]等则分别采用粒子群算法与遗传算法来优化神经网络参数或结构；张德亮[12]等探索了小波分析在需求序列分解中的应用；张靖昊[13]等引入了基于仿真推演大数据的预测新思路。尽管上述研究显著丰富了油料需求预测的技术工具箱，但仍存在两大共性问题：一是预测不确定性的量化缺失。多数模型输出为单一确定性点估计值，未提供如“预测值可能的波动范围”或“达成某保障水平的概率”等风险信息，使得保障决策缺乏概率依据，降低了预测准确性和指挥员对预测方法的信任度。二是预测与决策环节的脱节。预测精度提升并未自然转化为决策风险的降低，指挥员仍难以在短缺与过剩之间进行可量化的科学权衡。

为突破“有点估计、无风险量化”及“有预测、无优化决策”的双重瓶颈，本文引入基于贝叶斯岭回归(Bayesian Ridge Regression)的概率化预测与决策框架(相关思想在系统辨识、故障预警等领域已得到验证[14]-[16])，构建了基于贝叶斯岭回归的油料需求预测决策模型。该模型兼具岭回归的稳定性和贝叶斯方法的概率化优势，通过输出完整的后验预测分布，能实现对预测风险的科学量化；通过将军事损失函数与后验分布相结合，能实现基于风险偏好的贝叶斯最优决策。这一研究路径为实现从追求最准猜测到

管理可知风险的范式转变提供了可借鉴的方法思路,为联合作战油料需求预测提供了风险可感知、决策可优化的理论框架与计算工具。

2. 基于贝叶斯岭回归的油料需求预测决策模型

2.1. 岭回归

在油料需求预测中,多元线性回归模型常用于建立油料保障需求的影响因素与油料需求量之间的关系。

2.1.1. 模型设定

设有 n 个观测样本,每个样本有 d 个特征,标准线性回归模型可表示为

$$Y = X\beta + \varepsilon \quad (1)$$

其中, $Y = (y_1, y_2, \dots, y_n)^T$ 为 $n \times 1$ 的油料需求观测向量; $X = \begin{pmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1d} \\ 1 & x_{21} & x_{22} & \cdots & x_{2d} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nd} \end{pmatrix}$ 为 $n \times (d+1)$ 的设计矩阵,

其第一列为全 1 向量,对应截距项; $\beta = (\beta_0, \beta_1, \beta_2, \dots, \beta_d)^T$ 为 $(d+1) \times 1$ 的回归系数向量, β_0 为截距项; ε 为 $n \times 1$ 的误差向量,通常假设 $\varepsilon \sim N(0, \sigma^2 I_n)$ 。

当特征间存在多重共线性时,设计矩阵 $X^T X$ 接近奇异,普通最小二乘估计 $\hat{\beta}_{OLS} = (X^T X)^{-1} X^T Y$ 的方差显著增大,导致模型不稳定。岭回归(Ridge Regression)通过引入 L2 正则化项缓解这一问题,其优化目标函数为

$$\min \{ \|Y - X\beta\|^2 + \lambda \|\beta_R\|^2 \} \quad (2)$$

其中, $\|\cdot\|$ 表示向量的 L2 范数; $\lambda > 0$ 为正则化参数,通过交叉验证确定,控制模型的偏差 - 方差权衡; β_R 表示除截距项 β_0 外的 d 维系数向量,确保不对截距项进行正则化。

2.1.2. 参数估计

岭回归中回归系数向量的解析解为

$$\hat{\beta} = (X^T X + \Lambda)^{-1} X^T Y \quad (3)$$

其中, $\Lambda = \text{diag}\{0, \lambda, \dots, \lambda\}$ 为 $(d+1) \times (d+1)$ 对角矩阵,第一个对角线元素为 0 (对应截距项)。

2.1.3. 预测决策

对于新样本 $x_* = (1, x_{*1}, \dots, x_{*d})^T \in R^{d+1}$, 其响应变量 y_* 的点预测

$$\hat{y}_* = x_* \hat{\beta} \quad (4)$$

此即基于岭回归的油料需求估计值。更进一步,基于 $\hat{y}_*$ 的抽样分布构造预测区间。通常假设 $\hat{y}_* \sim N\left(x_* \hat{\beta}, \sigma^2 \left[1 + x_*^T (X^T X + \Lambda)^{-1} x_*\right]\right)$, 其中, σ^2 由残差方差估计。由此可得 $(1-\alpha) \times 100\%$ 的预测区间为

$$\hat{y}_* \pm t_{\frac{\alpha}{2}}(n-d-1) \cdot \hat{\sigma} \sqrt{1 + x_*^T (X^T X + \Lambda)^{-1} x_*} \quad (5)$$

2.2. 贝叶斯岭回归

贝叶斯岭回归是一种在线性回归中引入贝叶斯推断的方法,通过对回归系数施加高斯先验,并利用贝叶斯定理更新后验分布,从而得到参数的估计及其不确定性。

2.2.1. 模型设定

设有 n 个观测样本,每个样本有 d 个特征,第 i 个样本的第 j 个影响油料需求的特征为 x_{ij} ,油料需求量为 y_i 。考虑带有截距的线性模型

$$y_i = \beta_0 + \sum_{j=1}^d \beta_j x_{ij} + \varepsilon_i, i=1, 2, \dots, n \quad (6)$$

其中, β_0 为截距项, β_j 为第 j 个特征对应的回归系数, ε_i 为独立同分布的噪声项, $\varepsilon_i \sim N(0, \lambda^{-1})$, 这里 $\lambda = \frac{1}{\sigma^2}$ 为噪声精度。模型也可写为矩阵形式

$$Y = X\beta + \varepsilon \quad (7)$$

其中, X, Y, β, ε 与岭回归中含义相同。

2.2.2. 先验分布

贝叶斯框架下,所有权重参数和超参数均被视为随机变量,由此建立如下先验结构。

一是权重先验。设定回归系数向量 β 服从多元高斯先验,即

$$\beta \sim N(0, \delta^{-1}I) \quad (8)$$

其中, δ 为权重精度参数。值得一提的是,由于模型对所有回归系数施加相同的先验分布,设计矩阵 X (除对应截距项的全 1 列外)应进行标准化处理,以确保先验对每个特征的公平性,而对油料消耗向量 Y 进行中心化处理(减去其均值),使得零均值先验对截距项更为合理。

二是超参数先验。设定精度参数 δ 和 λ 均服从伽马先验

$$\delta \sim \text{Gamma}(a, b), \lambda \sim \text{Gamma}(c, d) \quad (9)$$

其中 a, b, c, d 为先验超参数,代表了对精度参数的初始信念。常见做法是将它们设置为弱信息先验,使得先验分布非常平坦,让数据在后验推断中占据主导地位,这是默认的、较为稳健的选择。

2.2.3. 后验分布与 MCMC 推断

为获得联合后验分布 $p(\beta, \delta, \lambda | X, Y)$, 可采用 Gibbs 采样算法进行 MCMC 模拟,依次从各参数的条件后验分布中采样。

权重 β 的条件后验: 给定 δ 和 λ , β 的后验分布为多元高斯分布

$$p(\beta | X, Y, \delta, \lambda) = N(\mu_n, \Sigma_n) \quad (10)$$

其中, $\Sigma_n = (\delta I + \lambda X^T X)^{-1}$, $\mu_n = \lambda \Sigma_n X^T Y$ 。

权重精度 δ 的条件后验: 给定 β 和 λ , δ 的后验分布为伽马分布

$$p(\delta | \beta) = \text{Gamma}\left(a + \frac{d+1}{2}, b + \frac{1}{2}\beta^T \beta\right) \quad (11)$$

噪声精度 λ 的条件后验: 给定 β 和 δ , λ 的后验分布为伽马分布

$$p(\lambda | X, Y, \beta) = \text{Gamma}\left(c + \frac{n}{2}, d + \frac{1}{2}\|Y - X\beta\|^2\right) \quad (12)$$

特别地, 当固定超参数 δ 和 λ , 权重 β 的后验分布 $p(\beta|X, Y, \delta, \lambda)$ 的均值 μ_n 等价于优化目标函数 $\|Y - X\beta\|^2 + \frac{\delta}{\lambda}\|\beta_R\|^2$ 的解, 这与经典岭回归在形式上是完全一致的, 其中正则化参数为 $\frac{\delta}{\lambda}$ 。由此, 贝叶斯岭回归可以理解为经典岭回归的概率化推广与拓展。

2.2.4. 预测决策

贝叶斯框架的核心优势在于它为决策提供了完整的后验预测分布。此分布不仅是预测工具, 更是连接模型与最终保障决策的桥梁。利用后验分布, 能更好地从基础预测推导出符合特定军事决策目标的最优方案。

对于新样本 $x_* = (1, x_{*1}, \dots, x_{*d})^T \in R^{d+1}$, 其响应变量 y_* 可通过 MCMC 后验样本近似

$$p(y_* | x_*, X, Y) \approx \frac{1}{M} \sum_{m=1}^M N(y_* | x_*^T \beta^{(m)}, (\lambda^{(m)})^{-1}) \quad (13)$$

其中, $\{\beta^{(m)}, \lambda^{(m)}\}_{m=1}^M$ 为 Gibbs 采样得到的 M 个后验样本。

设指挥员确定油料储备量为 a , 决策后果用损失函数 $L(y_*, a)$ 衡量, 即当实际需求为 y_* 时, 采取行动 a 造成的军事损失。基于后验预测分布, 可以自然地衍生出不同的预测输出, 服务于不同的决策目标。

(1) 基础决策

一是点预测。最常用的是后验预测分布均值, 对应于平方损失函数 $L(y_*, a) = (y_* - a)^2$ 下的最优决策

$$\hat{y}_* \approx \frac{1}{M} \sum_{m=1}^M x_*^T \beta^{(m)} \quad (14)$$

称之为均值决策。

二是区间预测。计算后验分布的 $\frac{\alpha}{2}$ 和 $1 - \frac{\alpha}{2}$ 分位数, 可以得到的 $(1 - \alpha) \times 100\%$ 后验预测区间。例如, 95% 预测区间由所有预测样本 $\{y_*^{(m)}\}_{m=1}^M$ 的 2.5% 和 97.5% 分位数确定, 其中 $y_*^{(m)}$ 来自于 $N(x_*^T \beta^{(m)}, (\lambda^{(m)})^{-1})$ 。这为指挥员提供了未来需求的可能波动范围, 是进行风险预判和制定应急预案的直接依据。

(2) 最优分位数决策

更进一步, 考虑到油料保障决策后果通常是非对称的: 短缺造成的任务失败风险损失远大于过剩造成的仓储与资金占用损失。为此, 定义非对称线性损失函数

$$L(y_*, a) = \begin{cases} c_s (y_* - a), & y_* > a \\ c_e (a - y_*), & y_* \leq a \end{cases} \quad (15)$$

其中, c_s 为单位短缺损失系数, c_e 为单位过剩损失系数。一般认为油料短缺的军事后果更为严重, 故应有 $c_s > c_e$ 。最优决策 a^* 应最小化后验期望损失

$$a^* = \arg \min_a \{E[L(y_*, a)]\} \quad (16)$$

该优化问题的解析解为

$$a^* = F^{-1}(\alpha), \alpha = \frac{c_s}{c_s + c_e} \quad (17)$$

其中, $F^{-1}(\alpha)$ 为后验预测分布的 α 分位数。这意味着, 最优储备量即为后验预测分布的 α 分位数, 由短

缺与过剩损失的相对大小决定。

最优分位数决策的步骤如下：

第 1 步：设定损失。根据任务评估 c_s 和 c_e ，计算分位数水平 $\alpha = \frac{c_s}{c_s + c_e}$ 。

第 2 步：生成预测。基于贝叶斯岭回归，通过 MCMC 采样获得后验预测样本。

第 3 步：计算决策。取后验预测样本的 α 分位数作为最优储备量 a^* 。

第 4 步：量化风险。计算保障水平 $P(y \leq a^*)$ 和短缺风险 $P(y > a^*)$ ，量化决策风险。

特别地， α 取 0.5，即后验预测分布的中位数，对应于绝对损失函数 $L(y_*, a) = |y_* - a|$ 下的最优决策。中位数决策对异常值不敏感，是另一种稳健的点预测选择； α 取 0.025 和 0.975，分别对应下界(低库存)和上界(高保障)两个不同决策策略，为两类风险偏好极端决策。

理论上看，贝叶斯岭回归不仅是一个预测模型，更是一个概率决策支持系统。它通过后验预测分布，将参数估计、预测不确定性和优化决策在统一的概率框架下无缝衔接。在油料保障这类高风险、损失非对称的军事决策中，最优分位数决策方法能够将短缺损失远大于过剩损失这一关键领域知识直接、严谨、量化地融入最优决策的计算中，实现风险自适应的智能保障，这是经典岭回归无法比拟的优势。

3. 算例验证

3.1. 数据描述与预处理

3.1.1. 数据来源

本文根据公开资料和经验数据，模拟推理生成了涵盖多种典型作战样式与战场条件的油料需求数据集，非真实数据，共包含 252 个样本，每个样本有 8 个特征和 1 个响应变量(油料需求量)。具体来说，每一次历史任务或模拟任务视为一个独立的任务剖面，该剖面由兵力规模、基数量、作战强度、里程数、行动样式、地理环境、装备工作时间、战损率 8 个维度的影响因素共同定义，输出为完成该任务所对应的总油料需求量。表 1 对各特征进行了说明。

Table 1. Description of features

表 1. 特征说明

特征	说明
兵力规模	出动的用油装备数量，为数值型。
基数量	所有用油装备的油箱容量总和，为数值型。
作战强度	区分高、中、低三个等级，采用德尔菲法进行量化打分获得。
里程数	用油装备行驶的总公里数，为数值型。
行动样式	区分进攻、机动、防御三种样式，采用德尔菲法进行量化打分获得。
地理环境	区分山地、丘陵、平原、近海、远海五种不同环境，采用德尔菲法进行量化打分获得。
装备工作时间	用油装备行驶的总工作时间，为数值型。
机动战损率	油料机动战损率和用油装备战损率的综合值，为数值型。

3.1.2. 统计描述与相关性分析


对油料需求数据集进行统计描述，并计算特征间的相关系数、特征与响应变量的相关系数，结果如表 2 和图 1 所示。

Table 2. Statistical description of the POL demand dataset**表 2.** 油料需求数据集的统计描述

特征	均值	标准差	最小值	最大值
x1	44.88	12.60	22.00	81.00
x2	70.15	3.66	29.50	77.75
x3	37.99	2.43	31.10	51.20
x4	100.82	8.43	79.30	136.20
x5	99.90	7.16	85.00	147.70
x6	59.41	5.25	47.20	87.30
x7	18.23	0.93	15.80	21.40
x8	19.15	8.37	0.00	47.50

注：x1~x8 分别代表兵力规模、基数量、作战强度、里程数、行动样式、地理环境、装备工作时间、战损率，y 代表油料消耗量。后文如果用到，含义相同。

根据图 1 所示数据，x3 与 x4、x5、x7，x4 与 x5、x6、x8，以及 x5 与 x6 这 7 对特征间的相关系数绝对值均超过 0.70，表明这些特征可能存在显著的多重共线性。为量化共线性程度，进一步计算了各特征的方差膨胀因子(VIF)，结果如图 2 所示。

**Figure 1.** Correlation coefficients between features and between features and response variables**图 1.** 特征间、特征与响应变量的相关系数




Figure 2. Variance inflation factors of feature variables

图 2. 特征变量的方差膨胀因子

由图 2 可以看到, x_4 、 x_5 、 x_6 三个特征的 VIF 值均高于 5, 证实了数据中确实存在多重共线性问题。同时, 特征与响应变量之间的相关系数普遍处于 0.60 至 0.95 之间, 说明二者具有较强的线性关联。在此情况下, 若采用传统最小二乘回归, 多重共线性将导致参数估计方差增大、结果不稳定。岭回归通过引入 L2 正则化项, 能够在保留所有特征信息的同时有效抑制共线性影响, 提升模型稳健性, 因而成为处理此类数据的适宜选择。

3.1.3. 数据标准化

使用训练集的均值和标准差对特征和响应变量进行标准化

$$\tilde{x}_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j}, \tilde{y}_i = \frac{y_i - \bar{y}}{s_y} \quad (18)$$

其中, $\bar{x}_j$ 和 s_j 为第 j 个特征的训练集均值和标准差, $\bar{y}$ 和 s_y 为响应变量的训练集均值和标准差。测试集使用相同的统计量进行标准化, 确保数据一致性。

3.2. 评价指标

为全面评估贝叶斯岭回归模型的预测性能、不确定性量化能力及决策支持能力, 采用三类指标进行综合分析。

预测性能上, 选取均方根误差(RMSE)、平均绝对误差(MAE)和决定系数(R^2)作为预测精度的评价指标。RMSE 与 MAE 衡量预测值与实际值的偏差程度, R^2 反映模型对数据变异性的解释能力, 分别为:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

其中, y_i 为实际需求值, $\hat{y}_i$ 为需求预测值, $\bar{y}$ 为实际需求均值。

不确定性量化上, 选取预测区间覆盖率(PIC)和平均区间宽度(MPIW)作为评价指标。PIC 衡量贝叶斯模型生成的指定置信水平预测区间的可靠性, 即实际观测值落在预测区间内的比例。MPIW 度量预测区

间的平均长度。

$$PIC = \frac{1}{n} \sum_{i=1}^n I(y_i \in [L_i, U_i]) \times 100\% \quad (19)$$

$$MPIW = \frac{1}{n} \sum_{i=1}^n (U_i - L_i) \quad (20)$$

其中, $[L_i, U_i]$ 为第 i 个样本的 95% 后验预测区间, $I(\cdot)$ 为指示函数。

决策效能上, 用决策综合代价及其标准差为评价指标。决策综合代价反映不同策略的期望决策总成本。决策综合代价的标准差则衡量各策略决策结果围绕其平均代价的波动程度, 用以评估策略的稳定性与鲁棒性。

定义一次实验中, 测试集中样本 i 的决策代价为

$$C(y_i, a_i) = c_s \max(0, y_i - a_i) + c_e \max(0, a_i - y_i) \quad (21)$$

其中, y_i 为实际需求量, a_i 为决策储备量, 不同策略下的 a_i 的取值不同。对于整个测试集, 一次实验的决策代价

$$TotalC = \sum_i C(y_i, a_i) \quad (22)$$

多次试验的测试集决策代价的平均值即为决策综合代价。决策综合代价的标准差则通过计算多次试验的测试集决策代价的标准差获得。

3.3. 实验设计

3.3.1. 对比基准与实验框架

为系统验证贝叶斯岭回归在油料需求预测中的有效性, 以传统岭回归作为核心对比基准, 按照“数据预处理、模型训练与调优、预测评估、决策模拟”的逻辑脉络展开实验, 具体包含四个阶段: 一是数据准备阶段。依据 2.3.1 节所述, 对原始特征数据进行标准化处理, 消除量纲差异。二是模型构建与调优阶段。分别构建贝叶斯岭回归模型和岭回归模型, 并采用交叉验证对超参数进行优化。三是性能评估阶段。在测试集上全面评估两类模型的预测精度、不确定性量化能力与决策支持能力。四是决策模拟阶段。通过比较两类模型在均值决策、中位数决策、最优分位数决策等方面的表现, 识别贝叶斯框架带来的价值。

为确保实验的严谨性与可比性, 两类模型在完全一致的实验条件下进行: 采用相同的数据划分(训练集、测试集), 执行相同的特征工程与标准化流程, 在相同的测试集上计算所有评价指标等。

3.3.2. 数据划分与模型配置

数据划分上, 采用随机抽样, 按照 8:2 的比例划分训练集与测试集, 确保两个数据集中目标变量的分布一致。为减少随机性影响, 重复划分 10 次并报告平均性能。

模型配置上, 岭回归模型的正则化参数 λ 在区间 $[10^{-3}, 10^3]$ 内以对数均匀尺度取 50 个候选值; 通过 5 折交叉验证确定最优 λ ; 模型参数基于正规方程求解获得, 在保证数值稳定性的同时具有较高的计算效率。贝叶斯岭回归基于 Gibbs 采样进行 MCMC 推断, 取超参数 $a = b = c = d = 0.1$, 形成弱信息先验; 进行 5000 次 MCMC 迭代, 其中前 1000 次为预烧期, 之后每间隔 5 次抽样一次, 最终获得 800 个近似独立的联合后验样本。

3.4. 结果分析与讨论

从预测性能与模型稳健性、不确定性量化与可解释性及决策效能三个维度, 与岭回归进行系统对比与深入分析。

3.4.1. 预测性能与模型稳健性

(1) 预测精度对比

基于 2.3 中的实验设置，贝叶斯岭回归和岭回归在训练集和测试集上的核心评价指标如表 3 所示(均为 10 次随机划分的平均值 $\pm$ 标准差)。其中，Train_R²、Train_RMSE、Train_MAE 表示训练集上的三个评价指标，Test_R²、Test_RMSE、Test_MAE 表示测试集上的三个评价指标。

Table 3. The core evaluation metrics of bayesian ridge regression and ridge regression

表 3. 贝叶斯岭回归与岭回归的核心评价指标

Method	岭回归	贝叶斯岭回归
Train_R ²	0.9608 $\pm$ 0.0049	0.9640 $\pm$ 0.0036
Train_RMSE	5.8340 $\pm$ 0.3094	5.5930 $\pm$ 0.2370
Train_MAE	4.3571 $\pm$ 0.2649	4.1924 $\pm$ 0.2128
Test_R ²	0.9510 $\pm$ 0.0384	0.9538 $\pm$ 0.0379
Test_RMSE	5.9403 $\pm$ 1.9182	5.7094 $\pm$ 1.7113
Test_MAE	4.1595 $\pm$ 0.6150	4.0078 $\pm$ 0.3616

表 3 数据表明，岭回归的预测性能非常出色，贝叶斯岭回归更是全方位优于岭回归。在训练集与测试集上，其 R² 分别提升 0.33%与 0.29%，RMSE 降低约 4%，MAE 降低 3.7%左右，显示出精度上的稳步改进。更为关键的是，贝叶斯方法显著增强了模型的稳定性与鲁棒性：所有评价指标的标准差均明显减小，尤其在测试集上，MAE 的标准差大幅下降 41.2%，意味着预测结果受数据随机波动的影响更小，重复实验的一致性更高。贝叶斯岭回归不仅继承了岭回归防止过拟合的优点，更进一步通过概率化建模降低了预测的不确定性，在实际应用中兼具了更高的准确性与可靠性。

为直观展示模型的预测效果，选取其中一次划分的测试集结果绘制散点对比图，如图 3 所示。从图 3 中可以看到，两种模型的预测点均紧密分布在参考线(y = x)两侧，且点簇高度重合，直观印证了二者预测结果的高度一致性。




Figure 3. Scatter comparison plot of predicted demand versus actual demand on the test set

图 3. 测试集上预测需求量与实际需求量散点对比图

(2) 残差分布

模型的可信度不仅取决于预测精度，更依赖于误差结构。基于与图 3 相同的单次划分测试集，计算两种模型的残差，其统计量如表 4 所示，残差分布直方图如图 4 所示。

Table 4. Comparison of residual-related statistics between the two models
表 4. 两种模型的残差相关统计量对比

统计量	岭回归	贝叶斯岭回归
均值	1.2458	1.0231
标准差	4.7824	4.4317
中位数	1.1894	1.1684
最小值	-8.1654	-8.66
25%分位数	-1.6985	-2.2389
75%分位数	5.1277	4.4574
最大值	10.3084	9.9263




Figure 4. Comparative histogram of residual distributions on the test set
图 4. 测试集残差分布对比直方图

综合分析表 4 与图 4 可以看到，相较于岭回归，贝叶斯岭回归展现出系统性偏差更小、预测稳定性更高、残差分布更集中的优势。具体而言，贝叶斯岭回归残差均值(1.0231)较岭回归(1.2458)更接近零，降低了 17.86%；标准差(4.4317)较岭回归(4.7824)降低 7.33%。残差分布曲线更为“瘦高”，残差在零附近的集中程度明显更高。

(3) 数据划分与样本量敏感性分析

鉴于预测精度结果表明两种模型在多次随机划分下均表现出良好的稳定性，这里我们仅基于单次随机划分(一次实验)进行了两组敏感性分析，旨在考察其性能随数据划分策略与样本量变化的趋势特征。

① 样本量敏感性：固定训练集与测试集的划分比例为 8:2，通过随机抽取的方式生成从 52 到 252 的不同总样本量数据集(以 20 为步长)，比较两种模型在测试集上的 R^2 、RMSE 和 MAE 指标的变化，结果如图 5 所示。

② 划分比例敏感性：固定总样本量为 252，分别按 6:4、7:3、8:2 和 9:1 的比例划分训练集和测试集，比较两种模型在测试集上的 R^2 、RMSE 和 MAE 指标的变化，结果如图 6 所示。




Figure 5. Performance comparison on the test set under different sample sizes (data split ratio: 8:2)
图 5. 不同样本量下的测试集上性能表现对比(数据划分 8:2)




Figure 6. Performance comparison on the test set under different data splits (sample size: 252)
图 6. 不同数据划分下的测试集上性能对比(样本量 252)

结合图 5 和图 6 发现，相较于岭回归，贝叶斯岭回归对实验条件变化不敏感，稳健性更为突出。一是在不同样本量下，贝叶斯岭回归在 66.7%的情况下取得了更高的测试集 R^2 ，在 75%的情况下取得了更低的平均绝对误差(MAE)。二是在不同数据划分下，贝叶斯岭回归测试集性能的波动更小：其 R^2 的标准差(0.026)低于岭回归(0.028)，RMSE 的标准差(0.537)也低于岭回归(0.616)。两项指标协同降低，表明其预测结果更稳定。

综上，贝叶斯岭回归不仅在预测精度上略胜一筹，更在模型稳定性和过拟合控制方面表现出明显优势。这验证了贝叶斯框架通过先验分布平衡偏差与方差的特性，使其特别适用于样本量有限、数据划分不确定的油料保障预测场景。

3.4.2. 不确定性量化分析

确认贝叶斯岭回归具备比岭回归略优的预测性能后，进一步重点分析其不确定性量化能力。

(1) 回归系数对比与不确定性分析

基于一次代表性随机划分(样本量 252，划分比例 8:2)，对比了两种模型的回归系数估计。表 5 展示了两模型的系数估计值，并特别呈现了贝叶斯方法提供的后验标准差、95%可信区间及其是否包含零的统计信息，从而直观反映参数估计的稳定性与统计显著性。

Table 5. Comparison of regression coefficients and uncertainty analysis
表 5. 回归系数对比与不确定性分析

变量	岭回归			贝叶斯岭回归			对比		
	估计值	后验均值	后验标准差	95%置信 区间下限	95%置信 区间上限	是否包含 0	系数差异	方向	变化趋势
Intercept	-285.8228	-300.3403	10.3450	-320.4218	-278.1720	否	-14.5174	-	--
x1	-0.0707	-0.0648	0.0429	-0.1557	0.0155	是	0.0060	-	收缩
x2	0.8368	0.8962	0.1220	0.6585	1.1318	否	0.0594	+	扩张
x3	1.5316	1.2999	0.3328	0.6326	1.9487	否	-0.2317	+	收缩
x4	0.9107	1.0053	0.1211	0.7692	1.2415	否	0.0946	+	扩张
x5	1.3444	1.7995	0.1711	1.4726	2.1345	否	0.4551	+	扩张
x6	1.0158	0.6609	0.2080	0.2528	1.0822	否	-0.3549	+	收缩
x7	3.3541	2.6491	0.7359	1.1826	4.1253	否	-0.7049	+	收缩
x8	0.1653	0.0533	0.0747	-0.0908	0.2053	是	-0.1120	+	收缩
Intercept	-285.8228	-300.3403	10.3450	-320.4218	-278.1720	否	-14.5174	-	--

表 5 数据表明，贝叶斯岭回归在三个关键维度上深化了我们对模型的理解：首先，在特征重要性判定上，贝叶斯岭回归提供了基于概率的判断。例如，岭回归判定 x8 具有明确的正向影响(0.1653)，但其贝叶斯岭回归提供的 95%置信区间(-0.0908, 0.2053)包含零，这意味着该特征的统计显著性存疑，为特征筛选提供了更可靠的依据。其次，量化了估计的确定性。通过后验标准差(如 x1 的 0.0429 较小，x7 的 0.7359 较大)直观揭示了不同系数估计的置信程度。最后，贝叶斯方法展现了自适应的正则化效果——并非对所有系数进行均匀压缩，而是依据数据证据进行差异化调整，例如收缩了特征 3、6、7 的系数，却扩张了特征 2、4、5 的系数。这凸显了贝叶斯框架能够更灵活、更丰富地融合数据与先验信息，提供更

全面的不确定性刻画和更稳健的系数推断。

(2) 预测区间校准

预测区间的校准评估需要统计稳定性,为此这里基于 10 次随机划分实验,计算了不同置信水平下区间覆盖率的均值与标准差,如图 7 (左)所示;预测区间宽度的均值与标准差,如图 7 (右)所示。




Figure 7. Prediction interval calibration analysis: coverage rate(left) and interval width(right)

图 7. 预测区间校准分析: 覆盖率(左)与区间宽度(右)

图 7 结果表明,在区间覆盖率上,两种模型的覆盖率均值均略高于名义置信水平,表明预测区间稍显保守。例如,在 50%置信水平下,实际覆盖率约为 61.6%~61.8%;随着置信水平提高,覆盖率逐渐接近理论值(如 99%水平下接近 99%)。在区间宽度上,贝叶斯岭回归的平均区间宽度在所有置信水平下均小于岭回归(如 95%水平下为 23.30 vs 23.83),且宽度的标准差也更低,表明贝叶斯方法能提供精确、更稳定的预测区间。

综上,贝叶斯岭回归在保持相近覆盖率的同时,实现了更窄、更稳定的预测区间,展现出更优的不确定性量化能力。尤其在较高置信水平下,其校准更准确(如 99%水平覆盖率几乎完美),验证了贝叶斯框架在平衡预测精度与可靠性方面的优势。

3.4.3. 决策效能分析

通过构建典型油料保障场景,并采用多种决策策略进行决策模拟,对比验证贝叶斯岭回归的决策效能。

(1) 典型油料保障场景构建

考虑某行动中某装甲部队承担进攻作战任务,为该装甲部队预测油料需求并做出决策,设定短缺损失系数 $c_s = 18$,过剩损失系数 $c_e = 2$ 。这一参数设定符合油料保障的基本权衡 - 任务中断的战场影响远大于油料过剩的拖累。基于此,可计算得到最优保障水平 $\alpha^* = \frac{c_e}{c_s + c_e} = 0.9$ 。

(2) 多策略保障效能分析

为评估不同决策策略的效能,在上述场景下进行 10 次随机实验,分别计算五种策略对应的平均短缺风险、决策综合代价的均值与标准差,结果汇总于表 6。

Table 6. Comparison of support effectiveness under different decision-making strategies
表 6. 不同决策策略下的保障效能对比

决策策略	α	平均短缺风险	决策综合代价(均值 $\pm$ 标准差)
岭回归	—	55.2%	2343.525 $\pm$ 511.644
贝叶斯中位数	0.5	59%	2313.610 $\pm$ 421.553
贝叶斯上界	0.975	1.4%	1219.921 $\pm$ 247.672
贝叶斯下界	0.025	98.2%	11201.097 $\pm$ 678.731
贝叶斯最优	0.9	8%	969.940 $\pm$ 277.853

表 6 数据清晰展示了不同决策策略在风险控制、成本效率和稳定性三个维度的显著差异。具体体现为：贝叶斯最优分位数策略(0.9 分位数)在风险与成本间取得最佳平衡，平均短缺风险为 8%，决策综合代价最低，且标准差相对较小。这表明该策略在有效控制风险的同时极大化降低了平均成本，且结果具有较好的稳定性，是综合表现最佳的策略。贝叶斯上界策略(0.975 分位数)是严格的风险规避选择，平均短缺风险极低(1.4%)，代价略高于最优策略(1219.921)，但其标准差最小(247.672)，说明其在多次实验中表现最稳定。该策略适合对短缺容忍度极低、追求确定性的场景。传统策略表现欠佳，两者的平均短缺风险均超过 55%，决策代价均较高(约 2300)，属于“高风险 - 高成本”模式。贝叶斯下界策略(0.025 分位数)为极端高风险案例，短缺风险高达 98.2%，决策代价(11201.097)是其他策略的 5~10 倍，表明该策略几乎不设防，不具备实际应用意义。

此外，对比平均短缺风险与理论短缺风险($1-\alpha$)可知，贝叶斯决策框架呈现出高度一致的风险控制精度。特别是，贝叶斯最优策略(分位数 0.9)的实际风险(8%)与理论目标(10%)高度吻合，证明了该模型能可靠地将决策者的风险偏好(分位数参数)转化为实际可预期的短缺概率。贝叶斯上界策略的实际风险(1.4%)也显著低于其理论目标(2.5%)，体现了其在极端风险规避下的超预期保障能力。相比之下，传统岭回归模型无法建立此种明确、可靠的风险 - 决策关联。

4. 结论

本文围绕联合作战油料保障中需求预测的不确定性量化与决策支撑薄弱问题，引入贝叶斯岭回归构建了“概率预测、风险决策”一体化框架。通过理论分析与算例验证，得出以下结论：在预测性能方面，贝叶斯岭回归在点预测精度上与传统岭回归相当，且展现出更稳定的泛化能力，验证了其作为可靠性预测模型的有效性。更重要的是，该方法能够输出完整的后验预测分布，所生成的预测区间具有良好的校准性，从而实现了对预测不确定性的科学量化，弥补了传统点估计“有精度、无信度”的局限。在决策效能方面，基于后验分布的贝叶斯决策可将油料保障决策的军事损失结构与预测不确定性有机融合。研究发现，贝叶斯最优决策策略相比传统点估计决策能显著降低决策综合代价，并表现出更优的稳定性。这证实了将概率预测嵌入保障决策能够有效提升资源配置的科学性与风险可控性。

本文为小样本、高维度、多共线性的油料保障数据提供了可量化不确定性的建模工具，为实现“依数据决策、按风险调配”的精准保障模式提供了可嵌入现有流程的决策支持方法，未来有待在真实战场数据环境中进一步校准与完善，后续研究可探索将模型扩展至更复杂的非线性贝叶斯体系，并开发动态战场环境下的在线更新机制，以持续提升方法的适应性与实用性。

参考文献

[1] 杨晓峰, 张克渠, 刘海峰. 浅谈大数据在军用油料供应保障中的应用[J]. 中国储运, 2020(8): 159-160.

-
- [2] 李忠国, 丁国勤, 陈日, 等. 军事斗争准备油料保障需求预测[J]. 兵器装备工程学报, 2018, 39(11): 114-117.
 - [3] 樊荣, 朱才朝, 陆思锡, 等. 支持向量机在航空兵部队油料需求量预测中的应用[J]. 重庆大学学报, 2012, 35(6): 38-42.
 - [4] 陆思锡, 周庆忠, 熊彪. 基于支持向量机的舰艇部队联合作战油料需求量预测研究[J]. 物流技术, 2013, 32(5): 468-470.
 - [5] 吴书金, 汪涛, 全琪. 基于模糊聚类 and 直觉模糊推理的合成旅油料需求预测[J]. 计算机系统应用, 2019, 28(12): 205-211.
 - [6] 吴书金, 汪涛, 全琪, 等. 基于灰色模糊推理的油料需求预测[J]. 计算机测量与控制, 2019, 27(9): 18-22.
 - [7] 周庆忠, 曾慧娥. 基于改进微粒群神经网络的油料储备预测[J]. 计算机仿真, 2013, 30(9): 314-317, 339.
 - [8] 陆思锡, 王帅, 熊彪. 基于灰色理论与 BP 神经网络的油料需求量组合预测[J]. 物流技术, 2016, 35(9): 160-163, 184.
 - [9] 夏秀峰, 刘权羲. 基于灰色神经网络的装甲部队油料需求预测[J]. 火力与指挥控制, 2014, 39(9): 91-95, 100.
 - [10] 龚杰, 雍歧东, 秦朝臻, 等. 基于改进粒子群算法的油料需求量优化组合预测方法[J]. 军事交通学院学报, 2017, 19(4): 84-89.
 - [11] 周伟祝, 宦婧, 孙媛. 遗传神经网络在保障资源需求预测中的应用[J]. 火力与指挥控制, 2013, 38(8): 72-75.
 - [12] 张德亮, 杨国利, 郭嘉, 等. 小波分析在油料需求预测中的应用[J]. 军事交通学院学报, 2014, 16(11): 86-90.
 - [13] 张靖昊, 曹毅, 马建良. 基于仿真推演大数据的海上编队油料消耗预测算法[J]. 指挥控制与仿真, 2025, 47(5): 144-149.
 - [14] 向国, 欧勇鹏, 陈君杰, 等. 应用贝叶斯岭回归模型辨识水下航行器水动力系数研究[J]. 海军工程大学学报, 2025, 37(1): 104-112.
 - [15] 刘杰, 杨迎泽, 姜天翔, 等. 一种基于贝叶斯岭回归的制动机气动阀故障预警方法[J]. 铁道车辆, 2025, 63(1): 123-129.
 - [16] 孙德红, 周亿迎, 蒋佳伶. 基于贝叶斯岭回归的长江航运服务业集聚动力机制研究[J]. 中国航海, 2024, 47(2): 48-55.