

DOI: 10.19650/j.cnki.cjsi.J2311096

变工况下基于迁移学习融合域内对齐的 机床主轴热误差模型*

郑悦,付国强,雷国强,周琳丰,朱思佩
(西南交通大学机械工程学院 成都 610031)

摘要:热误差建模和补偿是提高机床加工精度的重要手段。将得到的热误差模型应用到类似或相近任务中,对减少模型构建和数据收集的成本具有重要意义。本文提出了一种简易迁移学习(EasyTL)融合域内对齐的主轴热误差建模方法,以实现不同工况下误差模型的迁移复用。建立基于域内对齐和距离矩阵全组合择优的热误差迁移模型参数选取方法,获得最优组合。进一步分析不同类型的域内对齐和距离矩阵各自对模型迁移性能的影响。最后,将迁移模型与kNN典型机器学习模型和卷积神经网络深度模型进行比较验证,分别预测不同工况下主轴Z向和Y向的热误差。此外,根据预测的主轴热误差进行工件补偿加工实验。该方法为热误差建模及补偿提供了一种新思路。

关键词:数控机床;热误差建模;迁移学习;域内对齐;变工况

中图分类号: TH164 **文献标识码:** A **国家标准学科分类代码:** 460.50

Thermal error model of machine tool spindle based on in-domain alignment and transfer learning under variable working conditions

Zheng Yue, Fu Guoqiang, Lei Guoqiang, Zhou Linfeng, Zhu Sipei

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Thermal error modeling and compensation is an important tool to improve the machining accuracy of machine tools. It is important to apply the obtained thermal error models to similar tasks to reduce the cost of model construction and data collection. In this article, an easy transfer learning (EasyTL) with intra-domain alignment method for spindle thermal error modeling is proposed to realize the transfer reuse of error models under different working conditions. Further, the respective effects of different types of intra-domain alignment and distance matrices on model migration performance are analyzed. Finally, the EasyTL model is compared and validated with machine learning kNN and deep learning CNN to predict the thermal errors of the Z-direction and Y-direction of spindle under different working conditions, respectively. This method provides a new idea for modeling and compensating the thermal errors of machine spindles. In addition, a workpiece compensation machining experiment is carried out according to the thermal error of the spindle established by the thermal error prediction. The average error of the workpiece after compensation is reduced. This method provides a new idea for the thermal error modeling and compensation.

Keywords: CNC machine tools; thermal error modeling; transfer learning; in-domain alignment; variable operating conditions

0 引言

在零件加工过程中,几何误差和热误差是影响机床加工精度的主要因素,其中热误差占机床总误差的

40%~70%,采取措施来减少热误差对机床加工精度的影响是很有必要的^[1-3]。机床各个部件都会发生热变形从而存在热误差,影响机床整机精度^[4-6]。热误差补偿法通过建立热误差预测模型对热误差进行预测并加工过程中进行补偿,从而降低热误差对加工精度的影响^[7-10]。因

收稿日期:2023-02-24 Received Date: 2023-02-24

* 基金项目:国家自然科学基金(52175486,51805457)、四川省科技计划项目(2022YFG0218)、流体动力与机电系统国家重点实验室开放基金课题(GZKF-202104)、衢州市科技计划项目(2022K90)、中央高校基本科研业务费专项资金(2682022ZTPY061)项目资助

此,建立一个精度较高且实用性较高的热误差模型是进行热误差补偿的关键^[11-12]。

众多国内外学者将研究重点放在热误差模型的建立上。戴野等^[13]建立的自适应模糊神经网络(adaptive-network-based fuzzy inference system, ANFIS)热误差预测模型能有效地预测电主轴的热误差。刘璞凌等^[14]选出的关键温度点后,通过多元线性回归与多层感知器神经网络两种方式构建主轴径向热误差模型。常添渊等^[15]提出了一种基于免疫粒子群优化的反向传播神经网络(back propagation neural network optimized by immune particle swarm optimization, IA-PSO-BP)模型的电主轴热误差预测方法,使热误差补偿能力达到98.4%。张捷等^[16]提出了基于遗传算法及径向基函数(radial basis function, RBF)神经网络的综合建模方法,预测模型精度和鲁棒性都得到了显著提升。Wu等^[17]利用卷积神经网络(convolutional neural networks, CNN)作为一种自动提取输入数据特征的深度神经网络的特点,提出了基于热图像的数控机床主轴径向热误差建模方法。Tan等^[18]提出了分段融合最小二乘支持向量机(segment fusion least squares support vector machine, SF-LSSVM)热误差建模方法。上述方法都是假设训练数据和测试数据的概率分布相同,通过足够多的带标签的数据训练机器学习热误差模型,并根据分布一致性来直接预测热误差^[19]。这将导致两个无法避免的问题:模型的泛化性差和训练集要求大,但获取大量的标签数据通常是昂贵和耗时的^[20]。现如今的热误差模型只关注机床温度变量与热误差本身的关系,却忽略了工况变化、设备异构等因素的重要性^[21-22]。实际运用中,面临的则是不同工况下的模型预测,现有方法难以处理跨域的问题,这是相关研究效果不理想的主要原因^[23]。

迁移学习无需训练数据(源域)和目标数据(目标域)是同一概率分布采样得来,只需是相关任务^[24]。本文在现有研究基础上,引入简易迁移学习(easy transfer learning, EasyTL)技术^[25]进行机床主轴热误差建模的研究。探究域内对齐和距离度量方法各自对不同工况间迁移效果的影响,分别研究特征学习方法和距离矩阵的最优组合。以不同工况下主轴Z向和Y向的热误差为预测目标,分别将k最近邻(k-nearest neighbor, kNN)^[26]和CNN作为传统机器学习和深度学习的代表,与EasyTL一同进行机床主轴热误差预测实验。最后,进行了误差补偿实际工件切削试验。

1 基于迁移学习的主轴热误差建模

1.1 EasyTL

迁移学习将知识从一个标记良好的领域迁移到另一个相似但有标记或无标记的不同领域。现有的基于学习

的方法通常需要密集模型选择以及超参数的调整才能获得良好的结果。EasyTL专注于开发域内结构,是一种不需要模型选择和超参数调优的迁移方法。

EasyTL由两部分组成,域内对齐和域内规划。EasyTL的方法示意如图1所示。将 n_s 个源域 X_s 数据组成的样本集 $\Omega_s = \{\mathbf{x}_i^s\}_{i=1}^{n_s}$ 与 n_t 个目标域 X_t 数据组成的样本集 $\Omega_t = \{\mathbf{x}_j^t\}_{j=1}^{n_t}$ 。通过域内对齐,使源域 X_s 与目标域 X_t 之间的差异尽可能的小。值得注意的是,源域为 $X_s = \{\mathbf{x}_j^s, y_j^s\}_{j=1}^{n_s}$,目标域为 $X_t = \{\mathbf{x}_j^t\}_{j=1}^{n_t}$ 。 \mathbf{x}_j^s 为源域 X_s 中第 j 个数据, y_j^s 为源域 X_s 中第 j 个标签, \mathbf{x}_j^t 为目标域 X_t 中第 j 个数据。




图1 EasyTL方法的示意图

Fig. 1 The diagram of EasyTL

域内规划通过提出一个新的概率注释矩阵 M 来建立分类器模型。通过学习概率标注矩阵 M 来进行迁移学习,损失函数可表示为:

$$\mathcal{J} = \sum_j^{n_t} \sum_c^C D_{cj} M_{cj} \quad (1)$$

式中: D_{cj} 为距离矩阵中的一个值,表示 \mathbf{x}_j^t 与源域中第 c 类 $X_s^{(c)}$ 中心的距离; M_{cj} 表示目标域中第 j 个数据 \mathbf{x}_j^t 属于 c 类的标注概率, $0 \leq M_{cj} \leq 1, c \in \{1, \dots, C\}$ 。

选择的目标样本 \mathbf{x}_j^t 的类标签是 $\{M_{cj}\}$ 中的概率最大值对应的标签,其中 $j \in \{1, 2, \dots, n_t\}$ 。EasyTL技术不涉及任何显式调优的参数。

1.2 主轴热误差实验

机床温度和热误差测量的目的是获取机床温度场和热变形位移场的信息,为建立热误差模型并对热误差进行补偿提供基础。本文以机床VMC850为研究对象,机床整机上共布置30个温度传感器。采用五点法,结合电

涡流传感器和标准芯棒,分别测量主轴轴向(Z向)热伸长和径向(X向、Y向)热漂移。实验传感器布置图如图2所示。从停机状态开始,以2000 rpm的转速空载连续运行4 h,然后停机,期间按实验设定实时记录30个温度数据和热误差数据,图3为其中10个温度传感器和热误差的测量结果。由于机床主轴主要产生热误差的方向为轴向,本文仅一个主轴Y向以及主轴Z向热误差为例,进行机床主轴的热误差建模研究。




图2 传感器布置图
Fig. 2 Layout of sensors




图3 2000 rpm 的温度及热误差数据

Fig. 3 Temperature and thermal error data for 2000 rpm

转速是影响主轴热变形的主要工况参数。为研究不同工况下的热变形,考虑不同转速。本实验从机床的冷态开始,数据采集软件的采样间隔为5 s,工况如表1所示。

为研究不同工况下的热误差建模,考虑了主轴不用转速的情况,训练数据和测试数据都是从不同的工况中随机选取的。本次实验共收集了5组实验数据,包括两组不同时刻的2000 rpm、一组4000 rpm、一组未冷机下的4000 rpm,一组变转速1(2000、3000、4000、1000 rpm各1 h),以及一组变转速2,其中变转速2的具体工况如图4所示。




图4 变转速2的转速变化
Fig. 4 Variable speed 2

表1 工况

Table 1 Working conditions

数组	数据集	转速/rpm	工况
1	训练集	2000	空转
	测试集	2000	空转
2	训练集	2000	空转
	测试集	4000	空转
3	训练集	2000	空转
	测试集	4000	空转(未冷机)
4	训练集	2000	空转
	测试集	变转速1	空转
5	训练集	2000	空转
	测试集	变转速2	空转

2 面向不同工况的主轴热误差迁移模型

采用 EasyTL 对机床主轴热误差进行建模,其建模流程如图5所示。将采集到的数据进行数据划分,对温度数据进行滤波,并对主轴Z方向热误差进行打标签的预处理。针对 EasyTL 技术中不同的域内对齐及距离矩阵两两组合进行研究,以预测结果的残差最大值、残差平均值和残差方差3个作为指标,从而得到域内对齐的特征学习方法和度量方法的距离矩阵的最优组合。

2.1 域内对齐与距离度量方法

域内对齐可以消除原始空间中的特征畸变。现有的迁移特征学习方法也可以利用以前的域内规划方法进行扩展,以提高其性能。常用的特征学习方法包括关联对

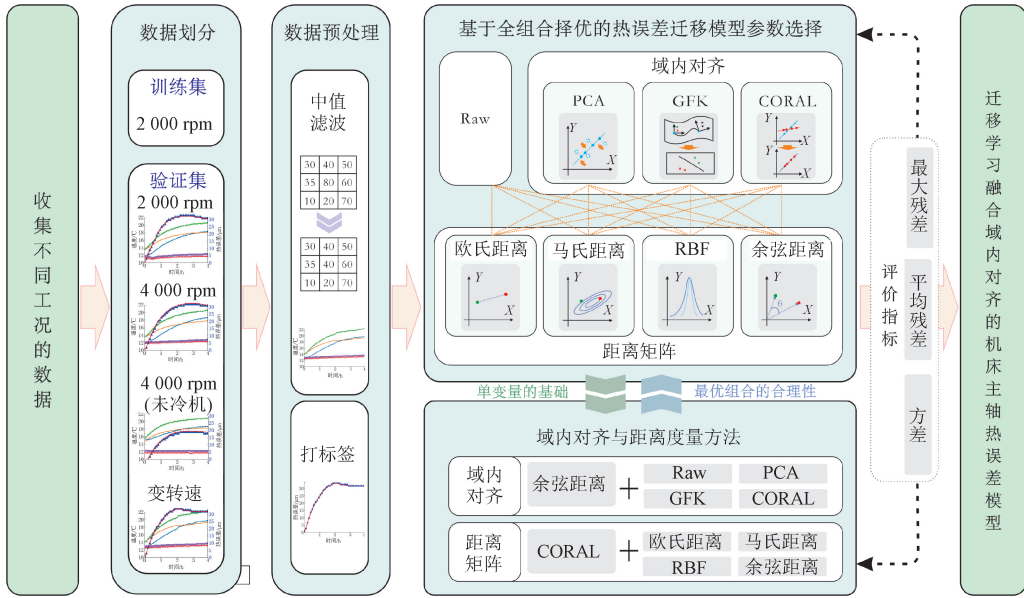


图5 基于 EasyTL 的主轴热误差建模流程

Fig. 5 Thermal error modeling flow chart of spindle based on EasyTL

齐 (correlation alignment, CORAL)、主成分分析 (principal component analysis, PCA) 和测地线流核 (geodesic flow kernel, GFK)。

CORAL 的主要思想是通过将源域和目标域特征的协方差进行结合,使用 CORAL 进行域内对齐的公式如式(2)所示。

$$\mathbf{Z} = \mathbf{X}_s (\mathbf{cov}(\mathbf{X}_s) + \mathbf{E}_s)^{-\frac{1}{2}} (\mathbf{cov}(\mathbf{X}_t) + \mathbf{E}_t)^{-\frac{1}{2}} \quad (2)$$

式中: $\mathbf{cov}(\cdot)$ 为协方差矩阵; \mathbf{E}_s 和 \mathbf{E}_t 形状分别与源域 \mathbf{X}_s 和目标域 \mathbf{X}_t 相等的单位矩阵。通过域内对齐进行特征转移后,再进行域内规划,学习出用于目标域热误差预测的非参数迁移模型。

PCA 对高维变量空间进行降维处理,使低维特征向量中的主成分变量保留原始变量的特征信息而消除冗余信息,从而得到降维后的目标矩阵 \mathbf{Z} :

$$\mathbf{Z} = \mathbf{W} \mathbf{X}_s \quad (3)$$

式中: \mathbf{W} 为 \mathbf{X}_s 的协方差矩阵 \mathbf{C} 对应的特征向量按行排列成的矩阵。

GFK 将源域和目标域映射到一个高维流形空间,使源域与目标域共享特征。 \mathbf{R}_s 为源域 \mathbf{X}_s 的正交补空间,满足 $\mathbf{R}_s^T \mathbf{X}_s = 0$,定义 $\mathbf{G}(d, D)$ 为所有 $D \times d$ 子空间的集合,设源域与目标域 GFK 核函数为:

$$\phi: t \in [0, 1] \rightarrow \phi(t) \in (d, D) \quad (4)$$

式中: $\phi(t) = \mathbf{X}_s \mathbf{U}_1 \Gamma(t) - \mathbf{R}_s \mathbf{U}_2 \Sigma(t)$, $\phi(0) = \mathbf{X}_s$, $\phi(1) = \mathbf{X}_t$ 。

SVD 分解 $\mathbf{X}_s^T \mathbf{X}_s$ 与 $\mathbf{R}_s^T \mathbf{P}_t$ 矩阵,其中 $\mathbf{U}_1, \mathbf{U}_2, \Gamma, \Sigma$ 分别由式(5)与(6)给出:

$$\mathbf{X}_s^T \mathbf{X}_s = \mathbf{U}_1 \mathbf{\Gamma} \mathbf{V}^T \quad (5)$$

$$\mathbf{R}_s^T \mathbf{X}_s = -\mathbf{U}_2 \mathbf{\Sigma} \mathbf{V}^T \quad (6)$$

GFK 内核被定义为:

$$\langle \mathbf{z}_i^s, \mathbf{z}_j^s \rangle = \int_0^1 (\phi(t)^T \mathbf{x}_i)^T (\phi(t)^T \mathbf{x}_j) dt = \mathbf{x}_i^T \mathbf{G} \mathbf{x}_j \quad (7)$$

式中: \mathbf{x}_i 和 \mathbf{x}_j 分别为未降维的原始数据集中的第 i 个和第 j 个数据。

GFK 内核 \mathbf{G} 最终解析式为:

$$\mathbf{G} = [\mathbf{X}_s \mathbf{U}_1, \mathbf{R}_s \mathbf{U}_2] \begin{bmatrix} \mathbf{A}_1 & \mathbf{A}_2 \\ \mathbf{A}_2 & \mathbf{A}_3 \end{bmatrix} \begin{bmatrix} \mathbf{U}_1^T \mathbf{X}_s^T \\ \mathbf{U}_2^T \mathbf{R}_s^T \end{bmatrix} \quad (8)$$

式中: $\mathbf{A}_{1i} = 1 + \frac{\sin(2\theta_i)}{2\theta_i}$, $\mathbf{A}_{2i} = 1 + \frac{\cos(2\theta_i) - 1}{2\theta_i}$, $\mathbf{A}_{3i} = 1 - \frac{\sin(2\theta_i)}{2\theta_i}$ 均为对角矩阵。通过 $\mathbf{Z} = \sqrt{\mathbf{G}} \mathbf{X}_s$, 在原始空间中的特征就可以被变换到高维流形空间中。

EasyTL 中距离矩阵 \mathbf{D} 除了余弦距离,还可使用常用的距离度量方法如马氏距离、欧氏距离,以及径向基函数 (radial basis function, RBF)。

马氏距离是一种有效的计算两个未知样本集的相似度的方法,其距离矩阵如式(9)所示。

$$\mathbf{D}_{ij} = \sqrt{(\mathbf{x}_i' - \mathbf{x}_j')^T \mathbf{C}^{-1} (\mathbf{x}_i' - \mathbf{x}_j')} \quad (9)$$

欧氏距离衡量的是多维空间中各个点之间的绝对距离。公式如下:

$$\mathbf{D}_{ij} = \|\mathbf{x}_i' - \mathbf{h}_c\|^2 \quad (10)$$

式中: \mathbf{h}_c 为源域中第 c 类 $\mathbf{X}_s^{(c)}$ 的中心。

RBF 为样本到数据中心之间径向距离的单调函数。本文中使用的 RBF 如式(11)所示。

$$D_{ij} = \exp(-\|x'_j - h_c\|^2) \quad (11)$$

2.2 基于全组合择优的热误差迁移模型参数选择

EasyTL 是一种构建非参数传递分类器,需分类处理热误差。图6为 $T_1 \sim T_5$ 温度传感器数据滤波和热误差数据的标签示意图,分别为 2 000、4 000 rpm、未冷机下的 4 000 rpm,以及变转速的。数字 0、1、2、 \dots 、 n 作为标签,共有 $n+1$ 类。

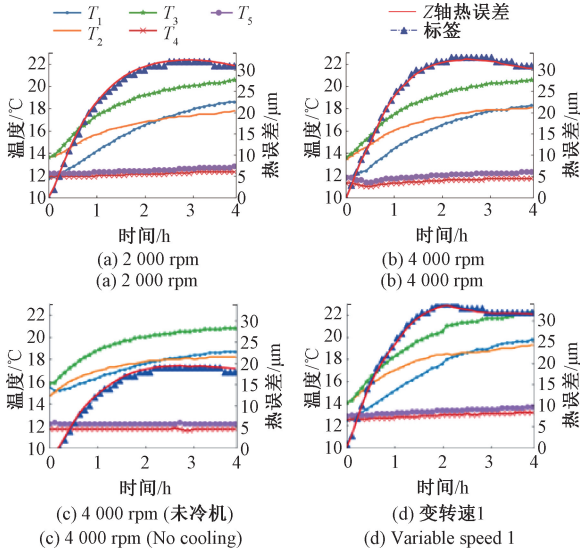


图6 数据预处理

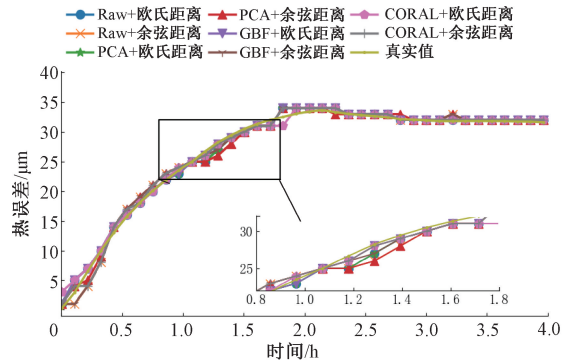
Fig. 6 Data preprocessing

为探究 EasyTL 技术中域内对齐与距离矩阵的最优组合,分别将未使用域内对齐方法 (Raw) 及 PCA、GBK 和 CORAL 这 3 种域内对齐方法,与欧氏距离、马氏距离、RBF 和余弦距离 4 种距离矩阵两两组合,共得出 16 种组合类型。依照表 1 中第 4 组进行实验,即使用 2 000 rpm 为训练集,变转速为测试集,分别对这 16 种组合方式的模型预测结果进行比较。16 种实验的残差和预测曲线如图 7 所示,预测结果的数据指标如表 2 所示。

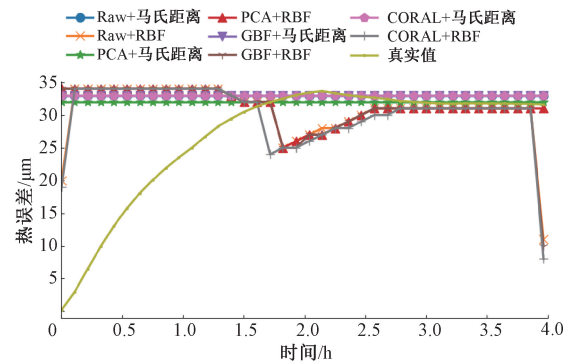
表 2 不同组合方式的预测结果

Table 2 Prediction results of different kernel functions

组合方式	Raw +欧氏	Raw +马氏	Raw +RBF	Raw +余弦	PCA +欧氏	PCA +马氏	PCA +RBF	PCA +余弦
最大残/ μm	2.91	32.75	33.25	2.68	2.91	31.75	33.75	2.68
平均残/ μm	0.15	6.09	4.45	0.04	0.14	5.09	4.23	0.06
方差/ μm^2	0.70	8.83	10.41	1.05	0.68	8.83	11.10	1.01
组合方式	GBF +欧氏	GBF +马氏	GBF +RBF	GBF +余弦	CORAL +欧氏	CORAL +马氏	CORAL +RBF	CORAL +余弦
最大残/ μm	2.91	32.75	33.75	2.68	2.91	31.76	21.75	2.68
平均残/ μm	0.15	6.09	4.45	0.07	0.13	4.76	-3.46	0.06
方差/ μm^2	0.69	8.83	10.79	1.00	0.72	8.75	10.62	0.93



(a) 8组实验结果1
(a) 8 sets of experimental results 1



(b) 8组实验结果2
(b) 8 sets of experimental results 2

图7 16种组合实验结果

Fig. 7 Experimental results of 16 combinations

结果表明,Raw+余弦距离、GBF+欧氏距离、GBF+余弦距离及 CORAL+余弦距离都能在不同的评价指标下分别得到最优的预测结果。由于 CORAL+余弦距离的组合同时在残差最大值及残差平均值两项指标内都为最优,选用该组合作为 EasyTL 技术中域内对齐和距离度量方法。

2.3 域内对齐与距离矩阵各自对迁移效果影响分析

为进一步探究不同的特征学习方法对 EasyTL 中域内对齐的影响,以余弦距离作为距离度量方法,分别使用

将 PCA、GBF 和 CORAL 与 EasyTL 结合的 3 种方法同未使用特征学习的 EasyTL 方法进行比较。4 种实验误差箱型图如图 8 所示。

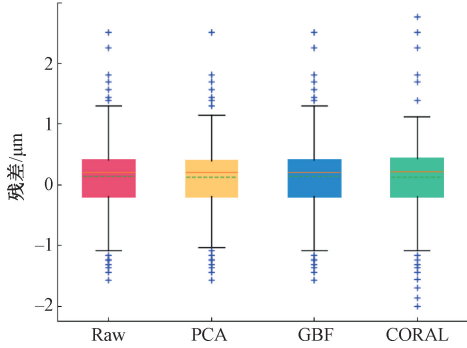


图 8 有无使用特征学习方法的 4 种误差箱型图

Fig.8 Error box plots with/without four feature learning methods

由于不使用域内对齐方法时已达到较好的迁移效果,4 个实验的预测结果差异并不大。使用了特征学习进行域内对齐后再进行 EasyTL 的迁移效果都表现得更好。其中, CORAL 的残差平均值最小,为 $0.13 \mu\text{m}$ 。同时,由于该算法简单方便,只需矩阵分解和相乘即可完成,高效率的同时不涉及任何参数调整,因此将 CORAL 选为 EasyTL 中域内对齐的特征学习方法。

为验证不同距离度量对特征迁移的影响,分别使用欧氏距离、马氏距离、RBF,以及余弦距离作为距离度量方法进行比较。4 种距离度量方法的实验预测结果如图 9 所示。

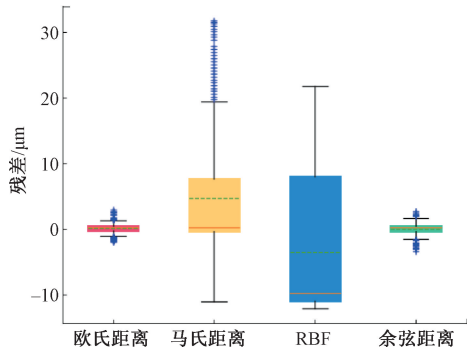


图 9 4 种距离矩阵的误差箱型图

Fig.9 Error box plots with four distance matrices

由图 9 结果可知,余弦距离作为 EasyTL 的度量方法效果最好,其预测结果的残差最大值为 $2.68 \mu\text{m}$,残差平均值为 $0.06 \mu\text{m}$,方差为 $0.93 \mu\text{m}^2$ 。欧氏距离的迁移效果仅次于余弦距离,其预测结果的残差最大值为 $2.90 \mu\text{m}$,残差平均值为 $0.13 \mu\text{m}$,方差为 $0.72 \mu\text{m}^2$ 。由于使用的数据集维度及其数据特点的原因,马氏距离和 RBF 在热误差模型上的预测效果并不理想,其最大残差都超过了 $20 \mu\text{m}$,平均残差也都在 $3 \mu\text{m}$ 以上,方差更是超过了 $8 \mu\text{m}^2$ 。由于余弦距离更适合解决异常值和数据

稀疏问题,对于特征向量很多的情况,即温度传感器收集了多个温度数据,余弦距离作为迁移学习的度量方法相比于其他 3 个表现更好。

通过上述实验可知,针对主轴热误差建模研究中使用的 EasyTL 技术,域内对齐采用 CORAL,同时度量方法采用余弦距离的组合方法最为有效。在热误差模型的实验验证部分,使用该最优组合的 EasyTL 技术与其余模型进行比较。

3 热误差模型的实验验证

根据第 2 节所得的 CORAL 和余弦距离的最佳组合方式构建出 EasyTL 模型。针对不同工况下热误差建模的问题,以 kNN、CNN 分别作为传统机器学习、深度学习的代表,与 EasyTL 进行模型比较,同样以预测结果的残差最大值、残差平均值和残差方差 3 个作为衡量指标,评价出最适用于不同工况的主轴热误差模型。分别进行相同和不同工况的热误差模型预测实验。最后,进行误差补偿实际工件切削试验。

3.1 相同工况下的热误差模型实验

为探究相同工况下 3 种热误差预测模型的性能,分别用这 3 种模型依照表 1 的第 1 组实验,即测试集为一组 2000 rpm ,验证集为另一时刻的一组 2000 rpm ,进行主轴热误差预测,并对 3 种模型的预测结果进行比较。其预测曲线如图 10 所示,预测结果的数据指标如表 3 所示。

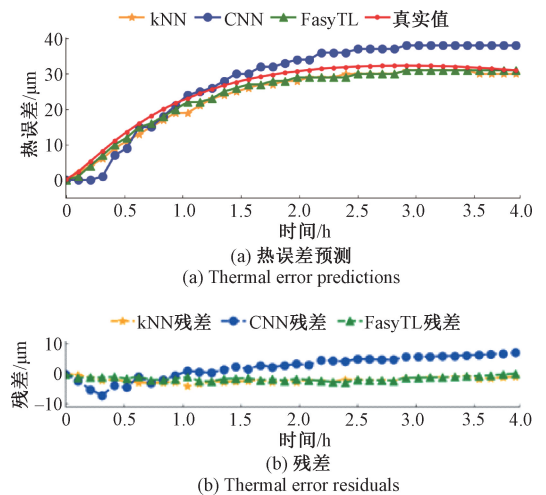


图 10 2000 rpm-2000 rpm 的实验预测结果

Fig.10 Experimental predictions of 2000 rpm-2000 rpm

由于环境温度及其他因素的影响,训练集与验证集的数据分部并不完全相同。因此,即使是相同工况的定转速实验,EasyTL 的性能也优于 kNN 和 CNN, EasyTL 的残差最大值为 $-0.02 \mu\text{m}$,残差平均值为 $-1.58 \mu\text{m}$,方差为 $0.72 \mu\text{m}^2$ 。

表3 定转速下3种模型的预测结果

Table 3 Prediction results of three models at certain speed

组数	模型	残差最大值/ μm	残差平均值/ μm	方差/ μm^2
1	kNN	-0.12	-2.08	0.85
	CNN	6.97	2.20	3.77
	EasyTL	-0.02	-1.58	0.72

3.2 不同工况下的热误差模型实验

为了探究不同工况下3种热误差模型的预测效果,依照表1的第2组、第3组、第4组和第5组进行4组实验。4组实验的预测曲线如图11所示,预测结果的数据指标如表4所示。




图11 实验预测结果


Fig. 11 Experimental prediction results

表4 不同工况下3种模型的预测结果

Table 4 Prediction results of three models under different conditions

组数	模型	残差最大值/ μm	残差平均值/ μm	方差/ μm^2
1	kNN	1.60	-1.58	1.66
	CNN	7.60	4.81	1.72
	EasyTL	5.18	0.89	1.17
2	kNN	0.98	-7.16	3.43
	CNN	0.98	-3.16	1.84
	EasyTL	2.24	1.46	0.52
3	kNN	0.03	-6.57	2.50
	CNN	6.42	1.90	3.07
	EasyTL	1.03	-0.83	0.66
4	kNN	3.50	1.43	1.61
	CNN	14.70	-6.30	5.50
	EasyTL	2.50	-0.40	0.82

实验结果显示,4种情况下 EasyTL 的性能都明显优于 kNN 和 CNN。同第1组式样一样,第2组实验中训练集和验证集的工作条件差异不大,3种模型的误差均可控制在 $10\ \mu\text{m}$ 以内。EasyTL 的性能略优于其他两种型号。3种模型的平均残差在 $-7.16\sim 4.81\ \mu\text{m}$,其中 kNN 和 CNN 的预测结果都略差于 EasyTL。当训练集和测试集之间的差距较大时,kNN 和 CNN 直接使用源域的监督信息来指导目标域的标签估计则会导致误差较大的结果。如第3组实验所示,测试集为未冷机下机床热误差数据,此时机床在0时刻的温度高于其在冷机状态下的温度。kNN 和 CNN 是由在冷机状态下以 $2\ 000\ \text{rpm}$ 训练的预测模型直接预测未冷机的机床在 $4\ 000\ \text{rpm}$ 条件下



的机床主轴热误差,因此这两种模型预测的热误差结果远偏离实际从0时刻开始的热误差。kNN和CNN预测的残差平均值分别为 -7.16 和 $-3.16\ \mu\text{m}$ 。EasyTL则通过域内比对预测热误差,域内比对和域内规划减少源和目标域的分布差异,从而实现不同工况下的迁移学习。其热误差的残差平均值为 $1.46\ \mu\text{m}$,且预测值在实际值周围波动且差异很小。在第4组变速实验中,kNN、EasyTL和CNN在前2 h内预测了相同的趋势。由于CNN模型对速度变化不敏感,导致2 h后的误差较大。kNN模型对转速变化较为敏感,但在变工况下预测的误差最大。EasyTL在预测变转速的情况下使其残差平均值在 $-0.83\ \mu\text{m}$ 。而在第5组复杂变工况的实验中,CNN在前2 h并没有有效预测出其变化趋势,残差最大值达到了 $14.7\ \mu\text{m}$ 。EasyTL在复杂工况下的3个预测指标在3个模型中都为最优。

主轴Y向同样进行了热误差建模实验。依照表1的第1组进行实验。根据主轴Z方向的预测实验结果,以及源域与目标域之间的差异性,选择表1中的第5组变速2作为检验所提方法通用性的实验。两组实验的预测曲线如图12所示。

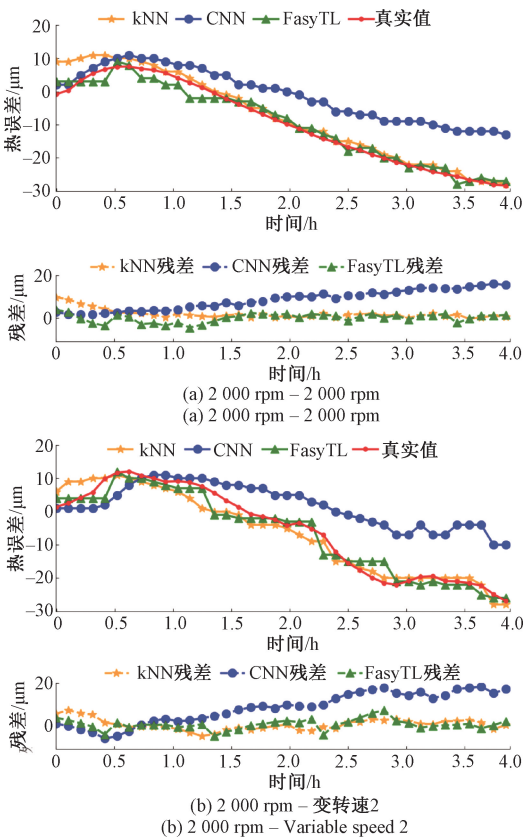


图12 主轴Y向实验预测结果


Fig. 12 Experimental predictions in Y-direction

在同工况的主轴Y向热误差预测试验中,kNN、CNN、EasyTL预测结果的残差平均值分别为 1.94 、 8.47 和 $0.05\ \mu\text{m}$ 。两组实验中CNN模型的预测效果都表现最差,其误差值最大值都约为 $20\ \mu\text{m}$ 。在复杂工况的实验中,与kNN模型相比,EasyTL的残差最大值、残差平均值和方差平均降低了 $3.1\ \mu\text{m}$ 、 $0.56\ \mu\text{m}$ 和 $0.15\ \mu\text{m}^2$ 。


由于各种工作条件之间的差异,若不对训练集进行扩展,kNN和CNN模型由于训练样本不够丰富导致其无法达到预期的结果。相比之下,EasyTL通过域内比对,只需一个训练集就可以实现比现有的机器学习和深度学习更好的效果。

3.3 工件加工实验

为验证EasyTL的机床主轴热误差建模的有效性,根据实验2预测的机床在 $4\ 000\ \text{rpm}$ 下的热误差进行补偿,并以 $4\ 000\ \text{rpm}$ 的转速对工件进行加工。根据ISO230-3机床热效应的测定试验规范,测量项目共20个,包括L1~L16的16个长度,H1~H4的4个高度,具体测量项目及工件实物如图13所示。采用CMM测量两个加工工件的各项数据。工件加工与误差测量的场景如图14所示。



(a) 测量项目
(a) Measuring item



(b) 加工工件
(b) Machining workpiece

图13 加工工件及其测量项目

Fig. 13 Machining workpiece and the measurement items

图15为有无补偿加工的两工件的误差降低率,各项误差结果如表5所示。与未进行补偿直接加工的工件相

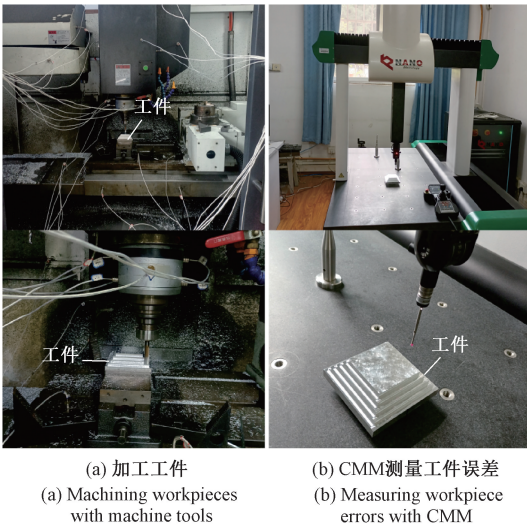


图 14 工件加工与误差测量

Fig. 14 Workpiece machining and error measurement

比,使用 EasyTL 获得的热误差进行补偿的工件误差更小,误差范围由 $[1.83, 157.93] \mu\text{m}$ 降至 $[0.01, 138.33] \mu\text{m}$,工件的平均误差由 $83.00 \mu\text{m}$ 降至 $49.96 \mu\text{m}$ 。其中,补偿效果最好的为 L14,误差从 $147.88 \mu\text{m}$ 降至 $24.03 \mu\text{m}$,精度提高了 $123.85 \mu\text{m}$ 。结果表明,EasyTL 能有效地预测多变工况下的机床热误差,依照所得热误差数据进行补偿,从而提高机床的加工精度。




图 15 有无补偿的加工工件误差降低率

Fig. 15 Errors with/without compensation

表 5 加工工件误差

Table 5 Errors in machining workpiece

误差	L1	L2	L3	L4	L5	L6	L7	L8	L9	L10	μm
未补偿	117.15	61.23	95.00	42.44	116.96	56.85	129.59	83.63	115.88	94.41	
补偿后	98.48	19.54	88.39	21.26	99.42	30.42	109.68	30.382	115.76	19.76	
误差	L11	L12	L13	L14	L15	L16	H1	H2	H3	H4	μm
未补偿	120.33	78.75	137.68	147.88	157.93	78.72	4.68	1.83	15.01	4.02	
补偿后	58.53	17.77	138.33	24.03	73.26	48.19	0.02	1.20	2.22	2.54	

4 结 论

为解决多变工况下机床主轴热误差建模成本高、泛化性差的问题,以传热理论和热变形机理为热误差模型能获取不同工况下的热变形的规律提供理论基础,提出一种基于 EasyTL 的领域自适应跨域特征融合方法,预测不同工况下机床的主轴热误差。在采集数据的数量以及丰富度有限的情况下,该模型具有更好的准确性与泛化性。

针对域内对齐,使用 PCA、GBF 和 CORAL 进行特征学习并结合 EasyTL 的 3 种方法同未使用特征学习的 EasyTL 方法进行比较,结果表明使用了特征学习进行域内对齐的 EasyTL 技术使得不同工况之间的迁移效果更好。

针对距离度量方法,使用余弦距离、马氏距离、欧氏距离,以及 RBF 作为距离度量方法进行比较,实验结果表明欧氏距离和余弦距离都能达到不错的迁移效果,余弦距离则能达到最好的迁移效果。

通过对比实验,将 kNN 和 CNN 分别作为典型的机器学习和深度学习算法代表,与所得的特征学习与位移矩阵 EasyTL 进行比较。源域和目标域的差异越大,EasyTL 方法的优越性越明显。实验结果表明,迁移学习的性能优于其他两种算法,在不同工况差异大的情况下其优势更为明显。

进行了误差补偿实际工件切削试验,根据模型预测所得的主轴热误差进行工件补偿加工,相比于未进行补偿的工件,补偿后的工件的平均误差降低了 46.28%,证明了建模方法的有效性。

参考文献

[1] 宋磊,刘阔,崔益铭,等. 基于机理驱动模型的卧式加工中心时变误差补偿[J]. 航空学报, 2022,43(7): 493-501.
SONG L, LIU K, CUI Y M, et al. Time-varying error compensation of horizontal machining center based on mechanism-driven model [J]. Acta Aeronautica ET Astronautica Sinica, 2022,43(7):493-501.

[2] LI G, TANG X, LI Z, et al. The temperature-sensitive

- point screening for spindle thermal error modeling based on IBGOA-feature selection[J]. Precision Engineering, 2022, DOI:10.1016/j.precisioneng.2021.08.021.
- [3] 谭峰, 殷鸣, 彭骥, 等. 基于集成 BP 神经网络的数控机床主轴热误差建模[J]. 计算机集成制造系统, 2018, 24(6):1383-1390.
- TAN F, YIN M, PENG J, et al. Thermal error modeling of CNC machine tool spindle based on integrated BP neural network [J]. Computer Integrated Manufacturing Systems, 2018, 24(6):1383-1390.
- [4] 况康, 王伟锋, 蒋东东, 等. 精密数控机床主轴热伸长补偿技术研究[J]. 机械与电子, 2021, 39(2):3-7.
- KUANG K, WANG W F, JIANG D D, et al. Research on thermal extension compensation technology of precision CNC machine tool spindle [J]. Machinery & Electronics, 2021, 39(2):3-7.
- [5] 刘阔, 韩伟, 王永青, 等. 数控机床进给轴热误差补偿技术研究综述[J]. 机械工程学报, 2021, 57(3):156-173.
- LIU K, HAN W, WANG Y Q, et al. Review of thermal error compensation technology for feed shaft of NC machine tool [J]. Journal of Mechanical Engineering, 2021, 57(3):156-173.
- [6] 姜辉, 杨建国, 姚晓栋, 等. 数控机床主轴热漂移误差基于贝叶斯推断的最小二乘支持向量机建模[J]. 机械工程学报, 2013, 49(15):115-121.
- JIANG H, YANG J G, YAO X D, et al. Numerical control machine tool spindle thermal drift error modeling based on Bayesian inference least-squares support vector machine [J]. Journal of Mechanical Engineering, 2013, 49(15):115-121.
- [7] 于士玉. 热变形机理与数据驱动融合的电主轴热误差建模方法研究[D]. 武汉: 武汉理工大学, 2020.
- YU SH Y. Research on thermal error modeling method of electric spindle based on thermal deformation mechanism and data-driven fusion [D]. Wuhan: Wuhan University of Technology, 2020.
- [8] 康程铭, 赵春雨, 付立新. 基于物理建模法的加工中心主轴热误差建模[J]. 东北大学学报(自然科学版), 2020, 41(4):528-533.
- KANG CH M, ZHAO CH Y, FU L X. Thermal error modeling of machining center spindle based on physical modeling method [J]. Journal of Northeastern University (Natural Science Edition), 2020, 41(4):528-533.
- [9] LIN C J, SU X Y, HU C H, et al. A linear regression thermal displacement lathe spindle model[J]. Energies, 2020, 13(4):949.
- [10] 马驰, 杨军, 梅雪松, 等. 基于遗传算法及 BP 网络的主轴热误差建模[J]. 计算机集成制造系统, 2015, 21(10):2627-2636.
- MA CH, YANG J, MEI X S, et al. Thermal error modeling of spindle based on genetic algorithm and BP network[J]. Computer Integrated Manufacturing Systems, 2015, 21(10):2627-2636.
- [11] 李高强. 一种基于 GA-LSSVM 的数控机床主轴热误差建模与补偿方法研究[D]. 南昌: 南昌大学, 2020.
- LI G Q. Research on thermal error modeling and compensation method of CNC machine tool spindle based on GA-LSSVM [D]. Nanchang: Nanchang University, 2020.
- [12] 张海妮. 基于改进 RBF 网络的加工中心主轴热误差建模研究[J]. 自动化技术与应用, 2019, 38(1):60-64.
- ZHANG H N. Research on thermal error modeling of machining center spindle based on improved RBF network [J]. Automation Technology and Application, 2019, 38(1):60-64.
- [13] 戴野, 尹相茗, 魏文强, 等. 基于 ANFIS 的高速电主轴热误差建模研究[J]. 仪器仪表学报, 2020, 41(6):50-58.
- DAI Y, YIN X M, WEI W Q, et al. Thermal error modeling of high-speed motorized spindle based on ANFIS [J]. Chinese Journal of Scientific Instrument, 2020, 41(6):50-58.
- [14] 刘璞凌, 杜正春, 冯晓冰, 等. 基于工件尺寸的数控机床热误差建模与补偿[J]. 机械设计与研究, 2020, 36(5):122-125.
- LIU P L, DU ZH CH, FENG X B, et al. Thermal error modeling and compensation of NC machine tool based on workpiece size [J]. Machine Design and Research, 2020, 36(5):122-125.
- [15] 常添渊, 黄晓华. 基于 IA-PSO-BP 模型的电主轴热误差预测方法[J]. 机械与电子, 2020, 38(10):52-56.
- CHANG T Y, HUANG X H. Prediction method of thermal error of motorized spindle based on IA-PSO-BP model [J]. Machinery & Electronics, 2020, 38(10):52-56.
- [16] 张捷, 李岳, 王书亭, 等. 基于遗传 RBF 神经网络的高速电主轴热误差建模[J]. 华中科技大学学报(自然科学版), 2018, 46(7):73-77.
- ZHANG J, LI Y, WANG SH T, et al. Thermal error modeling of high-speed motorized spindle based on genetic RBF neural network [J]. Journal of Huazhong University of Science and Technology (Natural Science

- Edition), 2018,46(7):73-77.
- [17] WU C, XIANG S, XIANG W. Thermal error modeling of rotary axis based on convolutional neural network [J]. Journal of Manufacturing Science and Engineering, Transactions of the ASME, 2021, 143(5):051013.
- [18] TAN F, YIN G, ZHENG K, et al. Thermal error prediction of machine tool spindle using segment fusion LSSVM [J]. The International Journal of Advanced Manufacturing Technology, 2021, 116(1): 99-114.
- [19] YANG F, ZHANG W, TAO L, et al. Transfer learning strategies for deep learning-based PHM algorithms [J]. Applied Sciences (Switzerland), 2020, 10(7):2361.
- [20] WANG J, CHEN Y, FENG W, et al. Transfer learning with dynamic distribution adaptation [J]. ACM Transactions on Intelligent Systems and Technology, 2020, 11(1): 1-25.
- [21] CHEN Y, ZHOU H, CHEN J, et al. Spindle thermal error modeling method considering the operating condition based on long short-term memory [J]. Engineering Research Express, 2021, 3(3):35019.
- [22] ABDULSHAHED A M, LONGSTAFF A P, FLETCHER S, et al. Thermal error modelling of machine tools based on ANFIS with fuzzy c-means clustering using a thermal imaging camera [J]. Applied Mathematical Modelling, 2015, 39(7): 1837-1852.
- [23] ZHAO S, QIU Z, HE Y. Transfer learning strategy for plastic pollution detection in soil: Calibration transfer from high-throughput HSI system to NIR sensor [J]. Chemosphere, 2021, 272:129908.
- [24] 邓柯楠, 高栋, 马守东, 等. 基于迁移学习的铣削机器人定位误差补偿方法[J]. 机械工程学报, 2022, 58(14):170-180.
- DENG K N, GAO D, MA SH D, et al. Localization error compensation method for milling robot based on transfer learning [J]. Journal of Mechanical Engineering, 2022, 58(14): 170-180.
- [25] WANG J, CHEN Y, YU H, et al. Easy transfer learning by exploiting intra-domain structures [C]. 2019 IEEE International Conference on Multimedia and Expo (ICME), Shanghai: IEEE, 2019: 1210-1215.
- [26] 王晓云, 王东琴, 郭金玉. 基于马氏距离 kNN 的多模态过程故障检测[J]. 沈阳大学学报(自然科学版), 2021, 33(6):480-485.
- WANG X Y, WANG D Q, GUO J Y. Fault detection for multimodal processes based on mahalanobis distance kNN [J]. Journal of Shenyang University (Natural Science), 201, 33(6):480-485.

作者简介



郑悦, 2020 年于西南石油大学获得学士学位, 现为西南交通大学硕士研究生, 主要研究方向为机床误差建模。

E-mail: zhengyue0404@163.com

Zheng Yue received her B. Sc. degree from Southwest Petroleum University in 2020. She is currently a master student at Southwest Jiaotong University. Her main research interest includes error modeling of machine tools.



付国强(通信作者), 2011 年获重庆大学学士学位。2016 年获浙江大学博士学位, 现为西南交通大学机械工程学院副教授。主要研究方向为机床精密测量、误差建模、机床辨识与补偿、CAM/CAD/CNC、精密制造。

E-mail: fuguogiang@swjtu.edu.cn

Fu Guoqiang (Corresponding author) received his B. Sc. degree from Chongqing University in 2011, and received his Ph. D. degree from Zhejiang University in 2016. He is currently an associate professor in mechanical engineering at Southwest Jiaotong University. His main research interests include precision measurement of machine tools, error modeling, identification and compensation of machine tools, CAM/CAD/CNC and precision manufacturing.