

基于半监督学习双模型结构的注塑产品异常检测

陈昱¹ 项薇^{1,2*} 林文文¹ 龚川¹ 张怀志¹ 虞任豪¹

1. 宁波大学机械工程与力学学院, 宁波, 315211

2. 浙江省零件轧制成形技术研究重点实验室, 宁波, 315211

摘要: 质量数据分布的不平衡及分类边界的模糊性限制了传统分类器的性能, 阻碍了企业智能生产决策的高效实施。为此, 提出了一种基于双模型结构的深度生成模型异常检测方法, 根据尺寸数据分布将合格产品等级进行二分类, 即优秀及次优, 分别用于训练两个深度生成模型, 考虑数据分布特点设计加权集成, 基于计算的异常分数对产品进行合格性判定。以变分自编码器(VAE)、Wasserstein生成对抗网络(WGAN)为子模型开发了两个双模型结构, 测试结果显示, 相较于单模型结构, 基于双模型的VAE和WGAN在测试集上的分类准确率分别提高了4.5%和6%。

关键词: 产品质量; 异常检测; 变分自编码器; Wasserstein生成对抗网络; 双模型结构

中图分类号: TP181

DOI: 10.3969/j.issn.1004-132X.2025.03.021

开放科学(资源服务)标识码(OSID):



Abnormal Detection of Injection Molding Products Based on Semi-supervised Learning Dual-model Structure

CHEN Yu¹ XIANG Wei^{1,2*} LIN Wenwen¹ GONG Chuan¹ ZHANG Huaizhi¹ YU Renhao¹

1. School of Mechanical Engineering and Mechanics, Ningbo University, Ningbo, Zhejiang, 315211

2. Zhejiang Provincial Key Laboratory of Part Rolling Technology, Ningbo, Zhejiang, 315211

Abstract: The imbalance in quality data distribution and the ambiguity of classification boundaries were identified as the factors limiting the performance of traditional classifiers, which hindered the efficient implementation of intelligent production decision-making in enterprises. Therefore, a dual-model-based deep generative model anomaly detection method was proposed. Qualified products were classified into two levels, excellent and sub-optimal, based on size data distribution, and two deep generative models were trained separately. A weighted ensemble strategy was designed considering characteristics of data distribution, and anomaly scores were calculated to determine product qualification. Two dual-model structures were developed based on VAE and WGAN. Experimental results indicate that, compared to single-model structures, the dual-model-based VAE and WGAN improve classification accuracy on the test sets by 4.5% and 6%, respectively.

Key words: product quality; anomaly detection; variational autoencoder (VAE); Wasserstein generative adversarial network (WGAN); dual-model structure

0 引言

工业制造中产品质量的检测关乎工厂的生产成本, 而制造业规模的扩大以及产品复杂性的提高均会导致产品废品率的提高^[1], 为了降低报废成本以及检测成本, 传统工厂一般会在生产线末端设置人工质检位。然而, 依靠人工质检会存在许多问题, 如: 无法进行全覆盖式检测, 废品流入后续加工环节中产生不必要的生产成本。随着人工智能的发展, 产品质量智能化检测方法被引入工厂质量管理, 这些方法可以分为监督式和半监督式。有监督学习需要使用同时包含合格品与不合格品的数据集去训练模型, 模型的效果在很大程度上取决于所提供数据集的大小和质量^[2]。同

时, 该方法需要为产品的每一类缺陷收集一定数量的样本, 并由负责质检的员工对这些样本的质量状况进行标记。然而, 现实生产中由于异常样本数量稀少、标记工作成本高等原因使得训练出高效的有监督模型十分困难。

与有监督学习相比, 采用半监督学习对产品质量进行异常检测可以规避上述问题。在制造领域的产品质量异常检测中, 半监督模型仅使用合格样本的工艺特征进行训练, 以学习合格品的数据分布。当模型对产品进行检测时, 会输出一个度量异常的指标, 如变分自编码器 (variational autoencoder, VAE) 会重构样本的输入, 将输入与输出进行比较, 可以计算出样本的重构误差; 生成对抗网络 (generative adversarial network,

GAN)则直接输出样本的异常概率;而高斯混合模型(Gaussian mixture model, GMM)会计算样本到其最近高斯分布的距离。接下来,将异常指标与人为设定的区分阈值进行比较,判断产品的合格性。

各类研究已将生成模型的异常检测能力拓展到了多个领域。CHEN 等^[3]利用滑动窗口来捕获工业机器人数据的时间依赖性,并构建了嵌有卷积结构的 VAE 模型,最终验证了该模型检测工业机器人工作异常的可行性。TANG 等^[4]开发了一个基于卷积自动编码器(convolutional autoencoder, CAE)的检测框架,并采用霍夫变换自动定位图像的重要位置,该框架实现了合格与报废产品的识别以及缺陷的定位。SONG 等^[5]首先利用包括递归图在内的三种编码方式将时间序列数据转化为了图像,再将其作为沿投影路径重建的变分自编码器模型(variational autoencoder-reconstruction along projection pathway, VAE-RaPP)的输入,该模型在训练后达到了 96% 的分类准确率。XU 等^[6]构建了由多尺度卷积流和卷积神经网络组成的模块,并用其提取图像特征,再通过注意门将该特征输入到生成对抗网络中,根据生成图像与原始图像的差异来区分正常样本和异常样本。LEHR 等^[7]用合格产品的图像训练了一个卷积自动编码器,用其对产品的质量进行检测,并进一步将 CAE 检测出来的缺陷产品进行聚类,以确定各产品的缺陷类型。CHEN 等^[8]构建了对抗性自编码器(adversarial autoencoder, DAE)模型来检测时间序列数据的异常,该模型由两个判别器以及一个自编码器组成,其中一个判别器用于隐变量的正则化,另一个则用于自编码器的对抗训练,以达到最小的重构误差。最终在 4 个数据集上证明了该模型检测时间序列异常的可行性。

综上所述,深度生成模型被证明在异常检测领域是有效的。而实际生产中,注塑过程中发生的冷却收缩、翘曲都会影响尺寸。对工厂而言尺寸稳定性是生产中关注的重点,所以本文以产品尺寸作为质量指标,对尺寸的合格性进行异常检测。然而,产品尺寸作为一个连续性质量指标,工厂在设置合格性判断边界时通常具有绝对性(如汽车配件生产厂家往往会根据具体的上下限来衡量某个尺寸的合格性),这会导致两个尺寸接近(工艺参数相似)但位于合格性边界两侧的产品被归为不同类别。使用这类数据训练模型会导致模型学习到的数据分布不准确,引发边界样本检测

模糊的问题。因此,需要特别关注模型对靠近合格性判定边界产品的检测准确率,故本研究将该类产品的异常检测作为非对称风险问题处理^[9],根据质量管理标准将合格产品细分为优秀产品和次优产品,考虑到两类合格品的工艺特征数据分布不同,用这两类合格品分别训练两个模型。再通过加权相加的方式将两个模型输出的异常分数进行集成,以此来应对由于数据本身局限产生的问题。最后,设定了区分阈值,并结合产品的异常分数对其质量进行分类。

1 基于双深度生成模型的注塑产品异常检测模型

本文提出的基于双模型异常检测的总体框架如图 1 所示,主要由数据处理、模型训练和异常检测 3 个模块组成。

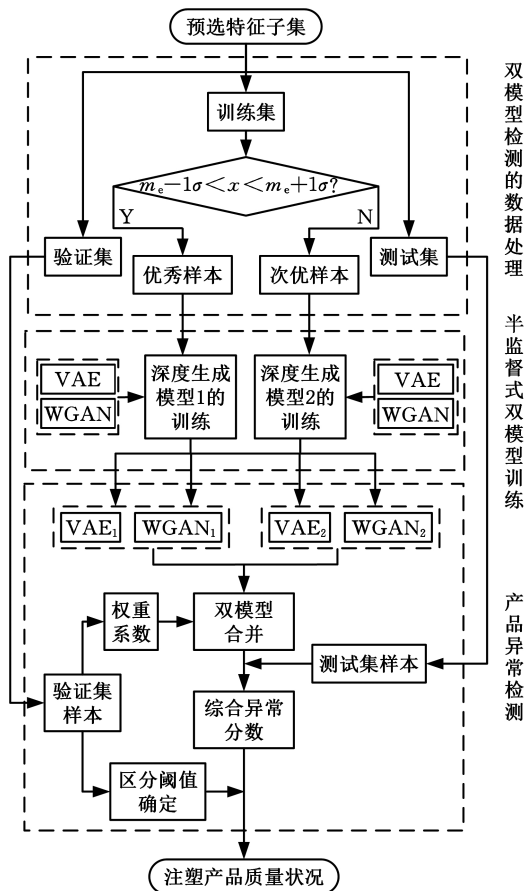


图 1 基于双模型结构的产品异常检测流程图
Fig.1 Product anomaly detection flow chart based on dual model structure

1.1 工艺特征处理

1.1.1 基于生产阶段的特征集构建

注塑过程可分为多个阶段,如注射、冷却和保压阶段等。为了获得完整的加工过程信息,工厂中配置了传感器来实时采集温度、压力等工艺参数的数值,并按一定采集频率进行记录。但对于

产品质量以及机器状态数据集而言,工厂通常都以模次级的数据粒度进行记录。为了合并各数据集,本文提取了高频特征的统计值,包括最值、中位数、方差、均值。将统计值特征与机器状态特征合并,即可获得一个能全面表征产品生产过程的特征集。

1.1.1.2 特征降维

采用特征选择对特征集进行降维,其目的是为了简化问题,降低学习任务的难度,提高模型的训练效率。基于特征子集的评价策略,可以将特征选择法分为过滤、包裹和嵌入法三大类。针对工业数据高维的特点,本文采用嵌入法挖掘特征子集,实现特征降维。嵌入法利用模型自身的特性和参数来选择特征。在模型训练过程中,会通过考虑特征的重要度,并根据特征对目标变量的贡献值进行选择和调整。此外,为了增强特征子集的普适性,本文选择多个评估模型共同计算特征的重要度。将这些特征按重要度排序后,筛选出重要特征作为特征子集。其中,第 i 个特征的综合重要度计算公式如下:

$$I_i = \frac{1}{m} \sum_{j=1}^m I_{i,j} \quad (1)$$

式中: m 为向后搜索模型的数量; $I_{i,j}$ 为第 j 个模型计算出的第 i 个特征的重要度。

1.2 注塑产品异常检测模型

半监督学习模型在数据不平衡时可以通过大量合格品数据,发掘合格品的数据分布。典型的模型包括自编码器、生成对抗网络等,这类半监督学习模型均适用于注塑产品的异常检测。本文选用了变分自编码器(VAE)与以 Wasserstein 距离作为模型损失函数的生成对抗网络(WGAN)作为子模型来实现产品质量异常检测的任务。

1.2.1 变分自编码器

VAE 是一种特殊的自动编码器(auto encoder, AE),它在自动编码器的基础上改进了隐藏层的表达方式。其本质上学习的是数据的分布情况,以最小化原始输入和重构值之间的重构误差为训练目标,采用 KL 散度来对两个分布进行距离衡量^[10]:

$$D_{kl}(p(x) \parallel p(\hat{x})) = \int p(x) \ln \frac{p(x)}{p(\hat{x})} dx \quad (2)$$

式中: $p(x)$ 为原始样本的分布; $p(\hat{x})$ 为重构样本的分布。

VAE 由两个概率密度分布模型构成,它的训练分为三步:

1) 编码部分。 $Q(z | x)$ 首先将原始数据转化为隐变量的概率分布,再进一步转化为均值与

方差。

2) VAE 进行采样时,由于均值与方差为固定值,会使得模型无法通过计算梯度来优化参数,故在训练时采用了重参数化,令均值和方差转化为变量,采样公式如下:

$$z = \mu + \epsilon\sigma \quad (3)$$

式中: z 为采样值; μ 为均值; σ 为标准差; ϵ 为从标准正态分布 $N(0, I)$ 中随机采样的值。

3) 解码部分。 $P(x | z)$ 会将隐变量的采样值 z 转化为重构样本。

由于这一过程中存在外部噪声,会使得 VAE 生成的新样本具有原始数据的某些特征,同时又具有差异性。对优化目标而言,VAE 希望编码器学习到的数据分布 $Q(z | x)$ 更接近原始数据分布 $p(x)$,即两个分布间的 KL 散度足够小,同时编码器 $P(x | z)$ 输出的样本与真实样本质检的重构误差足够小(通常使用均方误差来衡量)。VAE 模型的框架如图 2 所示。




图 2 VAE 模型的框架结构

Fig.2 The framework of VAE

1.2.2 生成对抗网络

GAN 是一种由生成器 G 和判别器 D 构成的模型。判别器的目标是识别出真实数据与生成数据,生成器的目标是生成近似于真实数据的样本,两者在训练过程中不断博弈,最终达到纳什均衡,模型结构如图 3 所示。但这一过程存在两个隐患。首先,在判别器最优且生成器生成数据的分布与原始数据分布没有重叠或者重叠部分可以忽略时,生成器的优化会出现梯度消失这一问题。其次,生成器的生成分布仅覆盖原始数据分布中的单一特征,会导致模式崩溃。为了解决上述问题,有学者提出了 WGAN(Wasserstein GAN),以 Wasserstein 距离代替了 JS 散度,以此来度量

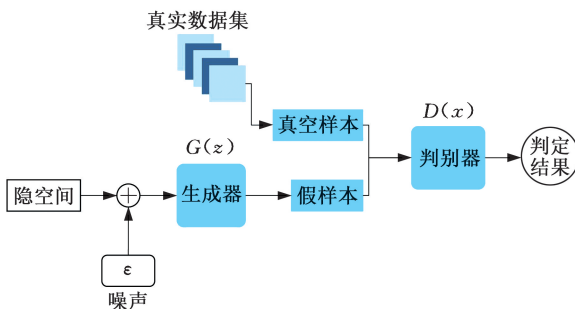


图 3 GAN 模型的框架结构

Fig.3 The framework of GAN

原始数据和生成数据分布之间的距离^[11]：

$$W(P_1, P_2) = \inf_{\gamma \sim \prod(P_1, P_2)} E_{(x, y) \sim \gamma} (\|x - y\|) \quad (4)$$

式中： P_1, P_2 为两个数据分布， $\prod(P_1, P_2)$ 为两个分布组合成的联合分布的集合； x, y 分别为 P_1, P_2 的采样值； $\inf(\cdot)$ 表示取下界，从分布集合中寻找使目标最小的联合分布； $E_{(x, y) \sim \gamma} (\|x - y\|)$ 表示根据联合分布 γ 计算样本点 x 和 y 之间的数学期望。Wasserstein 距离通过最优联合分布使该期望达到最小。

Wasserstein 距离相对 JS 散度具有更加优越的平滑性，可以解决梯度消失的问题，将判别器的参数数值范围进行限定后，推导出近似 Wasserstein 距离：

$$W = E_{x \sim P_r} (f_w(x)) - E_{x \sim P_g} (f_w(x)) \quad (5)$$

式中： P_r, P_g 分别表示原始样本分布和生成样本分布； f_w 为限制参数的判别器。

对 W 进行最大化时，该值就近似于真实分布与生成分布之间的 Wasserstein 距离。WGAN 保证了生成样本的多样性，并通过 Wasserstein 距离避免了模型在训练中的不稳定性和模式崩溃等问题。

1.3 基于双模型的异常检测

1.3.1 双模型方法

文献中均未对合格样本的类别进行细化，直接利用正常样本的数据来训练模型（即单模型），并基于这类模型（单模型）对产品的异常情况进行检测。单模型结构对靠近合格性判定边界样本的检测准确率较低，会导致部分不合格产品因误检而流入后续精加工中，造成额外的生产成本。针对这一现象，本文提出双模型结构，思路如下：首先，根据质量指标将合格品进一步细分为优秀产品与次优产品，并相对应生成两个训练集（单个训练集仅包含一种类别的合格品）；然后，分别用这两个训练集训练生成模型，再对两个模型输出的异常指标进行集成。

上述双模型结构具有以下两个优势：

1) 提高边界精度。通过细分合格品训练集，可以缓解单模型结构中边界样本模糊的现象，从而提高模型对边界附近样本的检测准确率。

2) 支持并行训练。两个模型在训练时并无逻辑关系，所以对双核设备而言，双模型可以并行训练，以节约训练时间。

1.3.2 异常指标

对产品进行异常检测时通常需要将模型输出的异常指标和设定的阈值进行比较。不同种类的深度生成模型在异常检测时产生不同的异常指标。对 VAE 而言，将待测样本分别输入两个模型

后，会分别输出一组特征的重构值，计算输入与输出间的重构误差 R ，即 VAE 模型的异常指标：

$$R = \frac{1}{n} \sum_{i=1}^n (f_i - \hat{f}_i)^2 \quad (6)$$

式中： f_i, \hat{f}_i 分别为样本第 i 个特征的原始值和重构值； n 为样本的特征数。

对 WGAN 而言，判别器会根据样本的数据分布输出相应的分类概率（样本为合格品的概率），该值即为 WGAN 的异常指标。

1.3.3 双 VAE 模型的集成

当采用双模型时，每个模型都会根据数据集样本对应生成重构误差，为了确定样本的最终重构误差，本文考虑使用加权相加的方法对两个模型输出的重构误差进行集成，并利用验证集数据来确定权重。在验证集中不再对合格品进行细分，该数据集中包含相同数量的合格品与不合格品。将验证集中的样本分别输入两个模型中，并计算出两组重构误差。考虑到两个 VAE 模型在同一样本上产生的重构误差数值级别上存在差异，故将两组重构误差各自进行归一化：

$$R' = \frac{R - \bar{R}}{\sigma} \quad (7)$$

式中： R, R' 分别为重构误差的原始值和标准值； \bar{R} 为特征的均值。

完成归一化后，某样本的综合重构误差 R_{VAE} 计算公式如下：

$$R_{VAE} = aR_1 + (1 - a)R_2 \quad (8)$$

式中： R_1 为第一个 VAE 模型对应的重构误差； R_2 为第二个 VAE 模型对应的重构误差； a 为权重。

1.3.4 双 WGAN 模型的集成

对 WGAN 双模型而言，两个模型分别对验证集样本输出两组分类概率，将结果各自归一化后，确定产品的综合分类概率 P_{WGAN} ，并将其作为最终的异常指标：

$$P_{WGAN} = bP_{c1} + (1 - b)P_{c2} \quad (9)$$

式中： P_{c1} 为样本在第一个 WGAN 模型中输出的分类概率； P_{c2} 为样本在第二个 WGAN 模型中输出的分类概率； b 为权重。

1.3.5 区分阈值

为了确定产品质量是否存在异常，本文根据待测样本的异常指标，结合阈值法对其进行判断。需要确定的合格性判定阈值与上述异常指标中的权重 a, b 均为超参数，故都需要通过验证集上的样本数据来确定最佳值。最后，在确定权重与区分阈值的情况下，对产品进行质量分类。在双 VAE 模型中，当某一样本的综合重构误差 R_{VAE} 大于区分阈值 T_1 时，将该样本归为不合格

品,否则判定为合格。对于以 WGAN 为子模型的结构,当某一样本的综合分类概率 P_{WGAN} 大于区分阈值 T_2 时,将该样本归为合格品,否则判定为不合格。产品异常判断过程如图 4 所示。

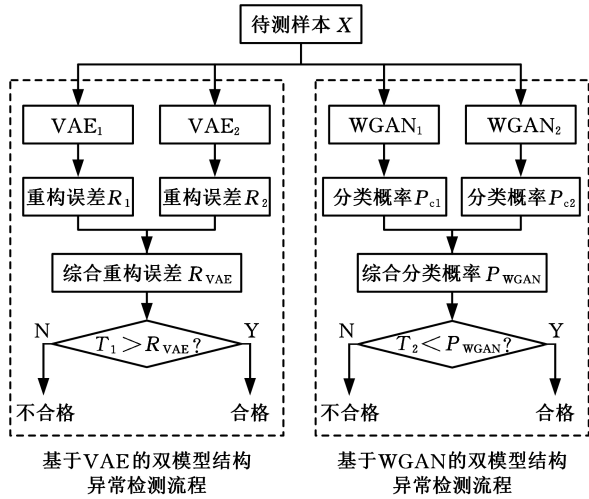


图 4 产品质量的判定过程

Fig.4 Product quality determination process

2 算例分析

为了验证所提方法的可行性,采用第四届工业大数据创新竞赛(注塑成形工艺的虚拟量测赛题)的数据集进行了验证。该数据集中包含:高频传感器采集数据、注塑机状态数据、产品尺寸测量值三类数据。

2.1 基于阶段的特征构建

高频传感器数据集中的数据由 22 个传感器以 20 Hz 或 50 Hz 的频率采集而来,每制造一个产品会对应记录约 1600 条采集值。而注塑机状态数据与产品测量尺寸以模次为单位进行记录。为了确保不同数据集间的数据粒度一致,本文将注射、保压、冷却、开模阶段的高频传感器采集值转化为模次级粒度的统计值(均值、标准差、最大值、最小值、中位数),形成了 440 个($4 \times 5 \times 22$)统计特征,如注射阶段模内压力传感器 1 的均值。将注塑机状态数据集中的单一值特征和空值特征删去后,与高频统计特征集合并,构建了一个含有 480 个变量的特征集。

2.2 关键特征的选择

上述构建的特征集中包含了大量与产品质量相关性低或互相存在冗余的特征,它们的存在不仅加重了模型训练时的负担,还会影响最终检测的准确率。因此,为了提高模型效率以及检测的准确性,需要对特征信息进行识别,进一步筛选出可以表征产品质量的关键特征,特征选择步骤如下:

本文采用了梯度提升树、随机森林、极度随机

树模型对特征的重要度进行计算,各个模型均筛选出对应重要度最高的 20 个特征,将三组特征合并,排除重复特征后构建了一个包含 45 个关键特征的特征集。

由于不同特征参数的数量级相差较大,会影响模型的训练,为此,在训练模型之前,需要先对特征进行标准化:

$$x' = \frac{x - \bar{x}}{\sigma} \quad (10)$$

式中: x 、 x' 分别为特征的原始值和标准值; \bar{x} 、 σ 分别为特征的均值和标准差。

2.3 非对称尺寸数据处理

本文以注塑产品的其中一个尺寸的质量合格性作为检测目标,该尺寸的上下限分别为 200.075 和 199.925,位于上下限间的样本即为合格品。经筛选,该数据集中包含 11 362 个合格样本以及 738 个不合格样本。

半监督模型的训练仅依靠合格品数据,所以训练集中只需包含合格样本。而为了确定双模型结构的两个超参数(区分阈值、异常指标权重)以及评估模型的准确率,需要设置验证集与测试集。为确保模型在评估时的公平性,避免偏差,以及构建有意义的混淆矩阵,本文将不合格样本以接近 4:3 的比例随机分入验证集与测试集,并从合格品数据集中随机挑选了相同数量的合格样本(300 个)分入测试集,用于最终的模型评估。接下来,需要将剩余的 11 062 个合格样本划分为训练集以及验证集的合格样本项,为了保证验证集中包含相同数量的合格样本与不合格样本,从剩余的合格样本集中随机挑选了 438 个样本分入验证集中,而剩余的 10 624 个合格样本作为初始训练集 data_1 。各数据集所包含样本数量如表 1 所示。

表 1 数据集划分结果

Tab.1 Dataset partitioning results

数据集	合格样本数量	不合格样本数量
data_1	10 624	0
验证集	438	438
测试集	300	300

为了确保模型的泛化能力,并确定合适的超参数,本文采用了交叉验证中的多次留出法,其主要思想是通过多次随机划分训练集与验证集,获得多组评估结果。对每组超参数组合进行验证,最终选择出平均性能最佳的超参数组合。

接下来,需要对训练集中的合格品样本类别进行细化。由于各样本的尺寸分布近似于正态分布,故将剩余合格品的质量等级按西格玛统计分

析确定^[12]。两类合格品的分类标准如下：满足 $m_e - \sigma < x < m_e + \sigma$ 的产品归为优秀产品集 $data_2$ (8749 个样本)；满足 $m_i \leq x \leq m_e - \sigma$ 和 $m_e + \sigma \leq x \leq m_m$ 的产品分到次优产品集 $data_3$ (1875 个样本)，其中， x 为产品尺寸值， σ 和 m_e 分别为尺寸的标准差和中位数， m_i 和 m_m 分别为尺寸的上下限。各训练集的参数如表 2 所示。

表 2 各训练集的参数

Tab.2 Parameters of each training set

训练集	尺寸 x 的范围	样本数
data ₁	(199.250, 200.075)	10 624
data ₂	(199.984, 200.050)	8749
data ₃	(199.250, 199.984) \cap (200.050, 200.075)	1875

2.4 基于双模型的异常检测

利用上述构建的 $data_2$ 和 $data_3$ 完成子模型的训练。首先构建以 VAE 为子模型的检测模块，分别用优秀产品集和次优产品集训练了 VAE₁ 和 VAE₂。对于输入的样本，两个模型分别会对该样本的特征值进行重构。随后，以式(6)计算出样本在两个模型中的重构误差，对两者进行归一化后，以式(8)确定样本的综合重构误差。接下来，需要通过验证集中的数据来确定两个子模型的权重以及区分阈值。

本文中选用了准确率 A 和 F_1 分数作为模型的评价指标

$$A = \frac{S_{TP} + S_{TN}}{S_{TP} + S_{TN} + S_{FP} + S_{FN}} \quad (11)$$

$$P = \frac{S_{TP}}{S_{TP} + S_{FP}} \quad (12)$$

$$R = \frac{S_{TP}}{S_{TP} + S_{FN}} \quad (13)$$

$$F_1 = \frac{2PR}{P + R} \quad (14)$$

式中： S_{TP} 为正确预测为正例的样本数； S_{TN} 为正确预测为负例的样本数； S_{FP} 为错误预测为正例的样本数； S_{FN} 为错误预测为负例的样本数。

权重 a 以 0.01 为步长在 $[0, 1]$ 范围内进行遍历。每一个权重条件下都会产生一组综合重构误差，区分阈值 T_1 以一定步长以合格类综合重构误差的较大四分位数为起点、不合格类综合重构误差的较小四分位数为终点进行搜索。以 F_1 分数为分类评价指标，确定每个权重对应的最佳阈值。最终会获得 100 组权重以及对应的区分阈值，从中挑选出使得模型在验证集上分类效果最好的超参数组合。使用相同的思路训练了 WGAN₁、WGAN₂，并确定了 WGAN 双模型结构的权重 b 以及区分阈值 T_2 。本文采用了 5 次留出法来确定最佳超参数，即对训练集以及验证集中

的合格样本项进行了 5 次随机划分。最终两个双模型结构的最佳权重与阈值如表 3 所示。

表 3 各结构的超参数

Tab.3 Hyperparameters of each structure

超参数	双 VAE 模型	双 WGAN 模型
权重	0.95	0.87
区分阈值	0.1060	0.5116

用训练好的模型检测测试集上的样本，并进行分类。图 5 为分类后的混淆矩阵，表 4 显示了各个分类指标，其中 F_Q 、 F_U 分别表示模型对于合格品以及不合格品的分类准确率。从图中可看出，基于 VAE 的双模型结构对于合格品的分类准确率较高，而基于 WGAN 的双模型结构对不合格品的分类准确率较高。工厂可以根据不同检测需求选择合适的模型。




图 5 基于双模型的异常检测结果

Fig.5 Abnormal detection results based on dual models

表 4 两模型在测试集上的分类准确率

Tab.4 Classification accuracy on two model test sets

模型	A	F_Q	F_U	F_1
VAE	0.900	0.953	0.847	0.905
WGAN	0.918	0.903	0.933	0.917

2.5 对比分析

为了验证双模型结构的有效性，本文搭建了单模型结构，训练时不再将合格品细分为优秀产品和次优产品，而是直接采用 $data_1$ 训练 VAE 与 WGAN。随后，通过验证集上的样本确定两个模型对应的区分阈值。此外，为了验证利用绝对性合格边界标记的数据在训练模型时存在局限，本文还确定了双模型结构中四个子模型 (VAE₁、VAE₂、WGAN₁、WGAN₂) 的分类准确率。各模型训练时所用的数据集如表 5 所示。将单模型结构、双模型结构、子模型的检测结果进行比较。各模型在测试集上的分类准确率如表 6 所示，训练时间如图 6 所示。

图 6 中，就双模型结构而言，图例模型 1 表示用优秀产品数据 $data_2$ 训练的模型，模型 2 表示用次优产品数据 $data_3$ 训练的模型。由表 6 可以看出，一方面用优秀产品集训练的子模型 (VAE₁、WGAN₁) 的分类准确率均高于单模型结

表 5 各模型训练所用的数据集

Tab.5 Data used for training each model

模型	训练所用数据集
VAE(单模型)	data ₁
WGAN(单模型)	data ₁
VAE ₁	data ₂
VAE ₂	data ₃
WGAN ₁	data ₂
WGAN ₂	data ₃
VAE(双模型)	data ₂ + data ₃

表 6 不同模型的分分类准确率比较

Tab.6 Comparison of classification accuracy of different models

模型	A	F _Q	F _U	F ₁	时间/s
VAE(单模型)	0.855	0.910	0.800	0.860	65.6
WGAN(单模型)	0.858	0.803	0.913	0.850	17.43
VAE ₁	0.858	0.937	0.780	0.870	27.7
VAE ₂	0.842	0.950	0.740	0.860	43.8
WGAN ₁	0.907	0.873	0.940	0.903	17.1
WGAN ₂	0.888	0.860	0.917	0.890	14.3
VAE(双模型)	0.900	0.953	0.847	0.905	43.8
WGAN(双模型)	0.918	0.903	0.933	0.917	17.1

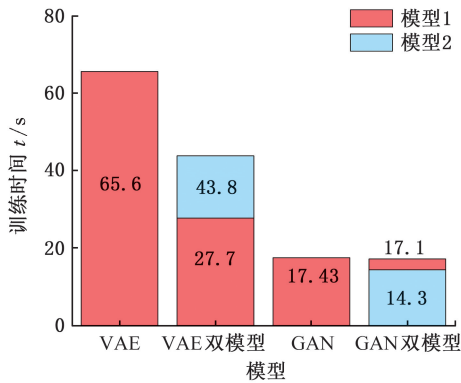


图 6 不同模型的训练时长

Fig.6 Training duration of different models

构。而用次优产品集训练的 WGAN₂ 的检测能力也优于 WGAN 单模型结构。由此可以得出,注塑工厂根据具有绝对性的合格判定边界标记产品质量,而利用这类数据集训练的半监督模型难以区分合格与不合格产品的数据分布,进而影响分类结果。另一方面,双模型结构的分类结果均优于各类子模型和单模型结构。此外,基于 VAE 的双模型结构对合格品的分类准确率较高,相对于单模型的 VAE 总分类准确率提高了 4.5%,训练时间降低了 21.8 s。相较于单模型结构的分类结果,基于 WGAN 的双模型结构的总分类准确率提高了 6%,对合格品的分类准确率提高了 10%。而将两类双模型结构的训练时间进行比较后发现,基于双 WGAN 模型的结构训练所需时间更少。

最后,为了证明本文提出方法的优越性,将检测结果与包括孤立森林、一类支持向量机在内的

异常检测领域基准模型进行了比较,结果见表 7。从表中可以看出,相较于两个基准模型,本文提出的双模型结构在各个分类准确率指标上都有一定提高,证明了本文提出方法的有效性。

表 7 基准模型检测结果与比较

Tab.7 Baseline model detection results and comparisons

模型	A	F _Q	F _U	F ₁
孤立森林	0.828	0.850	0.807	0.831
一类支持向量机	0.845	0.873	0.817	0.850
WGAN(双模型)	0.918	0.903	0.933	0.917

3 结论

本文提出了基于双模型结构的深度生成模型异常检测方法,首先将合格产品进行二分类,分别用于训练两个深度生成模型。对于一个待测样本,两个模型均会输出异常指标,采用加权相加的方式将两个模型的输出进行集成,最后结合区分阈值对产品的合格性进行判断。本文以变分自编码器(VAE); Wasserstein 生成对抗网络(WGAN)为子模型构建了两个双模型结构,与单模型结构的分类结果对比表明,在测试集上的分类准确率分别提高了 4.5% 和 6%。

参考文献:

- [1] HSIEH R J, CHOU J, HO C H. Unsupervised Online Anomaly Detection on Multivariate Sensing Time Series Data for Smart Manufacturing[C]// 2019 IEEE 12th Conference on Service-Oriented Computing and Applications (SOCA). Kaohsiung, 2019:90-97.
- [2] GUO Yu, ZHANG Jundong, SUN Bin, et al. Adversarial Deep Transfer Learning in Fault Diagnosis: Progress, Challenges, and Future Prospects[J]. Sensors, 2023, 23(16):7263.
- [3] CHEN Tingting, LIU Xueping, XIA Bizhong, et al. Unsupervised Anomaly Detection of Industrial Robots Using Sliding-window Convolutional Variational Autoencoder [J]. IEEE Access, 2020, 8: 47072-47081.
- [4] TANG Weitao, VIAN C M, TANG Ziyang, et al. Anomaly Detection of Core Failures in Die Casting X-ray Inspection Images Using a Convolutional Autoencoder [J]. Machine Vision and Applications, 2021, 32(4):102.
- [5] SONG J, LEE Y C, LEE J. Deep Generative Model with Time Series-image Encoding for Manufacturing Fault Detection in Die Casting Process[J]. Journal of Intelligent Manufacturing, 2023, 34(7):3001-3014.
- [6] XU Caie, NI Dandan, WANG Bingyan, et al. Two-

- stage Anomaly Detection for Positive Samples and Small Samples Based on Generative Adversarial Networks[J]. *Multimedia Tools and Applications*, 2023, 82(13):20197-20214.
- [7] LEHR J, SARGSYAN A, PAPE M, et al. Automated Optical Inspection Using Anomaly Detection and Unsupervised Defect Clustering[C]//2020 25th IEEE International Conference on Emerging Technologies and Factory Automation(ETFA). Vienna, 2020:1235-1238.
- [8] CHEN Xuanhao, DENG Liwei, HUANG Feiteng, et al. DAEMON: Unsupervised Anomaly Detection and Interpretation for Multivariate Time Series[C]//2021 IEEE 37th International Conference on Data Engineering(ICDE). Chania, 2021:2225-2230.
- [9] 刘永兴, 唐小琦, 钟靖龙, 等. 基于轻量级梯度提升机的非对称风险注塑成形产品尺寸预测模型[J]. *中国机械工程*, 2022, 33(8):965-969.
- LIU Yongxing, TANG Xiaoqi, ZHONG Jinglong, et al. Asymmetric Risk Injection Molding Product Size Prediction Model Based on LightGBM[J]. *China Mechanical Engineering*, 2022, 33(8):965-969.
- [10] 来杰, 王晓丹, 向前, 等. 自编码器及其应用综述[J]. *通信学报*, 2021, 42(9):218-230.
- LAI Jie, WANG Xiaodan, XIANG Qian, et al. Review on Autoencoder and Its Application[J]. *Journal on Communications*, 2021, 42(9):218-230.
- [11] 崔建明, 余茜, 刘铭. 基于 WGAN 的生成式信息隐写方法研究[J]. *河南理工大学学报(自然科学版)*, 2023, 42(3):146-152.
- CUI Jianming, YU Xi, LIU Ming. An Innovative Generative Information Steganography Method Based on Wasserstein GAN[J]. *Journal of Henan Polytechnic University (Natural Science)*, 2023, 42(3):146-152.
- [12] KIM J, LEE J Y. Development of a Quality Prediction Algorithm for an Injection Molding Process Considering Cavity Sensor and Vibration Data[J]. *International Journal of Precision Engineering and Manufacturing*, 2023, 24(6):901-914.
- (编辑 王旻玥)
-
- 作者简介:** 陈 昱, 男, 1999 年生, 硕士研究生。研究方向为制造系统工程。E-mail: 15058023546@163.com。项 薇* (通信作者), 女, 1971 年生, 教授。研究方向为人工智能在制造及服务系统管理中的应用。发表论文 50 余篇。E-mail: xiangwei@nbu.edu.cn。
- 本文引用格式:**
陈昱, 项薇, 林文文, 等. 基于半监督学习双模型结构的注塑产品异常检测[J]. *中国机械工程*, 2025, 36(3):576-583.
- CHEN Yu, XIANG Wei, LIN Wenwen, et al. Abnormal Detection of Injection Molding Products Based on Semi-supervised Learning Dual-model Structure[J]. *China Mechanical Engineering*, 2025, 36(3):576-583.
-
- (上接第 575 页)
- [3] SCHEGG P, DURIEZ C. Review on Generic Methods for Mechanical Modeling, Simulation and Control of Soft Robots[J]. *PLoS One*, 2022, 17(1): e0251059.
- [4] BRUDER D, FU Xun, GILLESPIE R B, et al. Data-driven Control of Soft Robots Using Koopman Operator Theory[J]. *IEEE Transactions on Robotics*, 2021, 37(3):948-961.
- [5] NARASINGAM A, KWON J S I. Application of Koopman Operator for Model-based Control of Fracture Propagation and Proppant Transport in Hydraulic Fracturing Operation [J]. *Journal of Process Control*, 2020, 91:25-36.
- [6] CAO Guizhou, HUO Benyan, YANG Lei, et al. Model-based Robust Tracking Control without Observers for Soft Bending Actuators[J]. *IEEE Robotics and Automation Letters*, 2021, 6(3):5175-5182.
- [7] XAVIER M S, FLEMING A J, YONG Y K. Non-linear Estimation and Control of Bending Soft Pneumatic Actuators Using Feedback Linearization and UKF[J]. *IEEE/ASME Transactions on Mechatronics*, 2022, 27(4):1919-1927.
- [8] WILLIAMS M O, KEVREKIDIS I G, ROWLEY C W. A Data-driven Approximation of the Koopman Operator: Extending Dynamic Mode Decomposition [J]. *Journal of Nonlinear Science*, 2015, 25(6): 1307-1346.
- [9] NAIDU D S. *Optimal Control Systems*[M]. Boca Raton: CRC Press, 2018.
- (编辑 王旻玥)
-
- 作者简介:** 关胜闯, 男, 1998 年生, 硕士研究生。研究方向为软体机器人建模与控制。E-mail: giky0915@163.com。刘兆冰* (通信作者), 男, 1983 年生, 副教授。研究方向为软体机器人建模与控制。E-mail: zhaobingliu@whut.edu.cn。
- 本文引用格式:**
关胜闯, 柳宇钧, 杨清昊, 等. 基于 LQR 和 UKF 的软体机器人无模型轨迹跟踪控制[J]. *中国机械工程*, 2025, 36(3):570-575.
- GUAN Shengchuang, LIU Yujun, YANG Qinghao, et al. Model-free Trajectory Tracking Control of Soft Robots Based on LQR and UKF[J]. *China Mechanical Engineering*, 2025, 36(3):570-575.