

电子科技大学
UNIVERSITY OF ELECTRONIC SCIENCE AND TECHNOLOGY OF CHINA

博士学位论文

DOCTORAL DISSERTATION

(电子科技大学图标)

论文题目 重型数控机床可靠性建模与评估技术研究

学科专业 机械工程

学号 201211080101

作者姓名 彭卫文

指导教师 黄洪钟 教授

分类号 _____ 密级 _____

UDC^{注1} _____

学 位 论 文

重型数控机床可靠性建模与评估技术研究

(题名和副题名)

彭卫文

(作者姓名)

指导教师

黄洪钟

教 授

电子科技大学

成 都

(姓名、职称、单位名称)

申请学位级别 博士 学科专业 机械工程

提交论文日期 2015.09.15 论文答辩日期 2015.11.30

学位授予单位和日期 电子科技大学 2015年12月

答辩委员会主席 _____

评阅人 _____

注1: 注明《国际十进分类法UDC》的类号。

Research on Methods for Reliability Modeling and Assessment of Heavy-Duty CNC Machine Tools

**A Doctor Dissertation Submitted to
University of Electronic Science and Technology of China**

Major: **Mechanical Engineering**

Author: **Peng Weiwen**

Advisor: **Prof. Huang Hong-Zhong**

School: **School of Mechatronics Engineering**

独创性声明

本人声明所呈交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。据我所知，除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得电子科技大学或其它教育机构的学位或证书而使用过的材料。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示谢意。

作者签名：_____ 日期： 年 月 日

论文使用授权

本学位论文作者完全了解电子科技大学有关保留、使用学位论文的规定，有权保留并向国家有关部门或机构送交论文的复印件和磁盘，允许论文被查阅和借阅。本人授权电子科技大学可以将学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。

（保密的学位论文在解密后应遵守此规定）

作者签名：_____ 导师签名：_____

日期： 年 月 日

摘 要

重型数控机床作为高精尖的国家战略性“工作母机”，肩负着多个关系国计民生和国防安全的关键产品和零部件的加工制造，其技术水平和可靠性的高低已成为影响制造业和国防安全的关键所在。近年来，在《装备制造业调整和振兴规划》以及《国家中长期科学和技术发展规划纲要(2006-2020年)》等规划的专项支持下，我国重型数控机床取得了“从小到大”的突破，填补了多个重点工业领域制造装备的空白。然而在机床型号和整机指标取得突破之后，国产重型数控机床却暴露出严重的可靠性问题：故障频发且无法追溯、性能波动且难以控制、维护成本高昂等。因此，迫切需要开展重型数控机床可靠性关键技术的研究，并着实构建重型数控机床寿命周期的可靠性技术体系。

重型数控机床可靠性建模与评估技术是关键的可信性基础共性技术，正确的可信性建模是开展可信性设计、可信性试验和可信性增长的重要前提，而精确的可信性评估则是对机床进行定量控制、研制考核和健康管理的关键手段。重型数控机床由于系统结构、制造装配、任务工况、使用维护等方面均有别于传统中小型数控机床，使得现有的可信性建模与评估技术难以适用。因此，针对重型数控机床的可信性建模与评估技术，已成为首当其冲的研究要点和亟待解决的应用难点。本论文在“高档数控机床与基础制造装备”科技重大专项课题的驱动下，针对重型数控机床的可信性建模与评估技术展开研究，主要内容和成果如下：

(1) 提出了考虑维修程度、故障关联程度和模型不确定性的故障时间数据建模与系统可信性评估方法。针对重型数控机床在寿命周期多因素的影响下，其故障时间数据并非独立同分布的问题，系统地研究了完好维修、最小维修和非完好维修下故障时间数据建模的方法。通过提出故障关联因子模型，并将其引入到故障时间数据模型中，形成了同时计及维修程度和故障关联程度的故障时间数据建模方法。针对重型数控机床故障时间数据难以采用单一模型建模分析的问题，提出了基于贝叶斯模型综合方法的故障时间数据分析和可信性评估方法，实现了多模型评估结果的综合以及模型不确定性的量化表征。

(2) 提出了基于贝叶斯方法和贝叶斯网络的多源层次信息融合评估方法。针对重型数控机床多源层次信息集中，信息的多样性、数据的覆盖性以及信息的主客观共存性等给可信性建模与评估带来的挑战，提出了系统层次结构和层次多类型数据的可信性建模方法，为多源层次信息的建模融合提供了基础。在此基础上构建了混合贝叶斯方法和贝叶斯网络模型的多源层次信息融合框架，在此框架下

突破了基于贝叶斯方法的独立来源层次客观数据的融合方法、基于贝叶斯网络的层次覆盖数据的融合方法、基于贝叶斯网络的层次主客观信息的融合方法，为重型数控机床基于多源层次信息集的可靠性建模与评估提供了系统的解决方案。

(3) 提出了轨迹形式多样化的性能演变过程建模方法，研究了基于贝叶斯方法的性能检测数据分析和可靠性评估方法。针对重型数控机床性能演变过程中，轨迹形式的多样性和个体之间的差异性，借助于性能退化建模的研究思路，研究了基于随机过程的性能演变过程建模方法。提出了性能演变速率模型并将其引入到逆高斯过程模型中，解决了轨迹多样性和个体差异性的性能演变过程建模问题。针对重型数控机床验证交付时，主机厂和用户厂性能检测数据协同分析的需求，提出了基于贝叶斯方法的模型参数估计、性能演变预测和剩余寿命评估等方法，实现了主机厂和用户厂性能检测数据的融合分析与可靠性的动态评估。

(4) 提出了动态环境与任务应力下多性能退化过程的建模方法，研究了基于贝叶斯方法的不完全状态监测数据分析与可靠性评估方法。针对重型数控机床在使用阶段，状态监测数据所呈现的性能指标的多样、环境工作应力的多变等问题，利用 Copula 函数、随机过程模型和协变量建模方法，构建了适用于多种退化轨迹形式的考虑动态环境工作应力的多性能退化模型。针对重型数控机床在不完全状态监测数据下，性能退化预测、剩余寿命评估以及结果不确定性表征的实际需求，提出了基于贝叶斯方法的多性能退化分析方法，重点研究了模型参数的两步估计法、缺失观测点和未来观测点的性能退化预测、考虑个体差异性的剩余寿命评估等方法，为重型数控机床的状态监测和健康管理提供了可靠性建模与评估技术的支撑。

关键词：重型数控机床，可靠性建模，可靠性评估，贝叶斯理论，性能退化分析

ABSTRACT

Heavy-duty CNC machine tools are now indispensable manufacturing equipment in many manufacturing sectors, such as aerospace, power equipment, shipbuilding, rail transportation and ocean engineering. The technical level, performance index and reliability status of heavy-duty CNC machine tools are getting more and more critical, especially for the continual prosperity of manufacturing industry, and the national security of our country. Under the guidance and support of national plans and projects, including the “Planning on Adjusting and Revitalizing the Manufacturing Industry” and the “Long-term Science and Technology Development Plan (2006-2020)”, great progresses have been made on the research and development of heavy-duty CNC machine tools. Various new types of heavy-duty CNC machine tools have been introduced, which successfully fill the gap of lacking heavy-duty CNC machine tools in many key industries. However, behind the breakthrough of heavy-duty CNC machine tools, the reliability of these machine tools is under great challenges. Various reliability issues raises among these newly introduced heavy-duty CNC machine tools, telling the very truth that we are quantitatively large but not competitively strong. Reliability engineering of heavy-duty CNC machine tools is consequently becoming an imperative research topic.

Reliability modeling and assessment are fundamental techniques within reliability engineering. Accurate reliability modeling is the prerequisite for reliability design, reliability test and reliability improvement. Precise reliability assessment can help the quantitative control and health management of machine tools. Due to various characteristics of heavy-duty CNC machine tools, which make them different from traditional manufacturing machine tools, various reliability modelling and assessment methods can hardly be used for heavy-duty CNC machine tools. Accordingly, it is critical to investigate the technique for reliability modeling and assessment of heavy-duty CNC machine tools.

Motivated by a practical project supported by the “High-end CNC Machine Tools and Basic Manufacturing Equipment” major science and technology project, this paper devotes to the research on methods for reliability modeling and assessment of heavy-duty CNC machine tools. Major research contributions and innovative outcomes

are summarized as follows.

(1) Development of a method for reliability modeling and assessment based on failure time data by taking account the effect of maintenance, failure-relevance and model uncertainty. Reliability of heavy-duty CNC machine tools is affected by various factors from the life cycle stages of design, manufacturing, usage and maintenance. The assumption of independently identically distributed failure time data is invalid in the modeling process. To solve this critical issue, a thorough investigation is carried out on the failure time data modeling under different maintenance situations, generating a serial of failure time models. A model for failure-relevance quantification is then proposed and incorporated into these models to construct the models for failure time data considering the effect of maintenance and failure-relevance. A reliability assessment method based on the Bayesian model averaging method is proposed to handle the problem of model uncertainty within the failure time data analysis.

(2) Development of a system reliability modeling and assessment method with multilevel heterogeneous data sets by leveraging Bayesian method and Bayesian network. The analysis of multilevel heterogeneous data sets is generally challenged by the modeling of data with different data types, handling overlapping data, as well as integrating objective and subjective information. A comprehensive Bayesian framework for the integration of multilevel heterogeneous data sets is presented. The pass-fail data, lifetime data, and degradation data at different system levels are combined coherently for system reliability analysis. An information fusion framework is constructed based on the Bayesian method and the Bayesian network. Within this framework, the technique for Bayesian integration of multiple independent heterogeneous data sets, the method for dealing with overlapping data set with Bayesian network, and the method for fusing objective and subjective information using Bayesian network are proposed. A comprehensive method for multilevel heterogeneous data modeling and reliability assessment is constructed for heavy-duty CNC machine tools.

(3) Development of stochastic process based models for degradation processes with constant, monotonic and S-shaped degradation rates. Other than a constant degradation rate, various patterns of time-varying degradation rates of degradation processes are often encountered in degradation modeling of heavy-duty CNC machine tools. By introducing a model of degradation rate, and incorporating it together with the random effect model into inverse Gaussian process models, the problem of degradation

modeling with time-varying degradation rate and unit-specific degradation process is resolved. Meanwhile, to facilitate the integration of degradation observations from both manufacturers and users of heavy-duty CNC machine tools, a general Bayesian integration framework is constructed. Degradation inference, reliability assessment, and residual life prediction are introduced within the Bayesian integration framework.

(4) Development of a method for degradation modeling under dynamic environmental and operating conditions. Degradation processes of heavy-duty CNC machine tools are generally characterized as multiple degradation processes with dynamic operating conditions. To model this kind of degradation processes, inverse Gaussian process model and Wiener process model are combined with Copula function to construct a general multiple degradation process model under dynamic environmental and operating conditions. Two types of dynamic covariates, including environmental conditions and operating profiles, are treated separately and incorporated into the proposed multiple degradation process model. To facilitate information integration and reliability analysis, Bayesian method is used to implement parameter estimation and degradation analysis. Reliability assessment for products' population, degradation prediction for missing observation points and for future observation points, as well as residual life prediction for individual products are investigated. Based on these methods, a solid foundation on degradation modeling and reliability analysis is constructed for further condition monitoring and health management of heavy-duty CNC machine tools.

Keywords: heavy-duty CNC machine tools, reliability modeling, reliability assessment, Bayes' theorem, degradation analysis

目 录

第一章 绪 论	1
1.1 研究背景和意义	1
1.2 研究现状	3
1.2.1 数控机床的可靠性建模与评估	3
1.2.2 基于故障时间数据的可靠性建模与评估	4
1.2.3 基于多源层次信息集的可靠性建模与评估	6
1.2.4 基于性能退化数据的可靠性建模与评估	7
1.2.5 综述总结与问题提出	8
1.3 论文的研究内容和结构	10
1.3.1 论文的研究内容	10
1.3.2 论文的总体结构	11
第二章 基于故障时间数据的重型数控机床可靠性建模与评估	13
2.1 引言	13
2.2 重型数控机床的故障时间数据	14
2.3 重型数控机床故障时间数据的建模	17
2.3.1 考虑维修程度的故障时间数据建模	17
2.3.2 考虑故障关联程度的故障时间数据建模	23
2.4 基于贝叶斯模型综合的重型数控机床可靠性评估	26
2.4.1 贝叶斯模型综合方法的基本框架	27
2.4.2 重型数控机床基于贝叶斯模型综合的可靠性评估实现	28
2.5 实例分析	37
2.5.1 现场故障时间数据	37
2.5.2 考虑维修程度和故障关联程度的故障时间数据建模	39
2.5.3 可靠性评估及结果分析	42
2.6 本章小结	45
第三章 基于多源层次信息集的重型数控机床可靠性建模与评估	46
3.1 引言	46
3.2 重型数控机床的多源层次信息集	47
3.3 重型数控机床多源层次信息集的可靠性建模	49
3.3.1 可靠性建模框架	49

3.3.2	系统层次结构的可靠性建模	50
3.3.3	系统多种类型可靠性数据的建模	52
3.4	基于混合贝叶斯网络的重型数控机床可靠性评估	55
3.4.1	基于贝叶斯网络的多源层次信息融合基本框架	56
3.4.2	多源层次信息的贝叶斯网络模型表达	59
3.4.3	多源层次信息的融合与系统可靠性评估	65
3.5	算例分析	68
3.5.1	多源层次信息集	69
3.5.2	信息集的层次贝叶斯模型与贝叶斯网络模型	71
3.5.3	系统可靠性评估	74
3.6	本章小结	75
第四章	基于性能检测数据的重型数控机床可靠性建模与评估	77
4.1	引言	77
4.2	重型数控机床的性能检测数据	79
4.3	重型数控机床性能检测数据的建模	79
4.3.1	基于随机过程的性能演变过程模型	80
4.3.2	性能演变速率形式多样的性能演变过程模型	83
4.3.3	考虑个体差异性和性能波动性的性能演变过程模型	87
4.4	基于性能检测数据的重型数控机床可靠性评估	89
4.4.1	基于贝叶斯方法的性能检测数据分析基本框架	89
4.4.2	性能检测数据分析的数学表达	91
4.4.3	融合主机厂与用户厂性能检测数据的贝叶斯可靠性评估	93
4.5	算例分析	98
4.5.1	性能检测数据	99
4.5.2	性能检测数据的建模与模型参数估计	100
4.5.3	模型验证与可靠性评估	102
4.6	本章小结	104
第五章	基于状态监测数据的重型数控机床可靠性建模与评估	106
5.1	引言	106
5.2	重型数控机床状态监测数据	107
5.3	重型数控机床状态监测数据的建模	108
5.3.1	动态环境与任务应力下多性能退化建模的基本框架	109
5.3.2	基于 Copula 的多性能退化建模	110

5.3.3 考虑动态环境与任务的多性能退化建模	114
5.4 基于状态监测数据的重型数控机床可靠性评估	116
5.4.1 基于贝叶斯方法的多性能退化分析的基本框架	116
5.4.2 多性能退化分析的数学表达	118
5.4.3 数据缺失情形下基于状态监测数据的可靠性评估	122
5.5 算例分析	126
5.5.1 状态监测数据	127
5.5.2 状态监测数据的建模与模型参数估计	128
5.5.3 模型验证、对比与重型卧车剩余寿命评估	133
5.6 本章小结	136
第六章 全文总结与展望	138
6.1 全文总结	138
6.2 后续工作展望	140
致 谢	141
参考文献	142
在学期间参与的项目研究	154
在学期间发表和录用的学术论文	155
在学期间申请的专利	157

图目录

图 1-1 论文的总框架图	12
图 2-1 故障时间序列数据	17
图 2-2 考虑故障关联程度的故障时间序列数据	24
图 2-3 故障关联因子对似然函数作用的示意图	25
图 2-4 贝叶斯模型综合方法的基本框架	27
图 2-5 模型与模型参数估计在 OpenBUGS 软件中的求解实现	35
图 2-6 完全维修假设下多个模型的拟合结果	39
图 2-7 模型变量 M 的后验分布	43
图 2-8 考虑维修程度和故障关联程度的 MTBF 估计值	43
图 2-9 不考虑维修程度和故障关联程度的 MTBF 估计值	44
图 3-1 系统的可靠性框图及其对应的多源层次信息集	49
图 3-2 考虑多源层次信息集的可靠性建模基本框架	50
图 3-3 贝叶斯网络示例	57
图 3-4 基于贝叶斯网络的多源层次信息融合基本框架	58
图 3-5 层次系统中底层节点和高层节点的贝叶斯网络模型	59
图 3-6 层次贝叶斯网络模型示例	60
图 3-7 成败型数据对应底层节点的贝叶斯网络模型	61
图 3-8 成败型数据对应高层节点的贝叶斯网络模型	61
图 3-9 寿命型数据对应节点的贝叶斯网络模型	62
图 3-10 退化型数据对应节点的贝叶斯网络模型	62
图 3-11 独立来源的层次客观数据的贝叶斯网络模型	63
图 3-12 主观信息的贝叶斯网络模型	64
图 3-13 信息相互覆盖的层次寿命数据的贝叶斯网络模型	67
图 3-14 多源层次主客观信息融合的贝叶斯网络模型	68
图 3-15 主轴系统简化可靠性框图模型	69
图 3-16 层次覆盖数据和主观信息融合的贝叶斯网络模型	73
图 3-17 主轴系统可靠性评估结果	75
图 4-1 恒定性能演变速率的性能演变过程示例	84
图 4-2 单调性能演变速率的性能演变过程示例	85
图 4-3 S 型性能演变速率的性能演变过程示例	86
图 4-4 基于贝叶斯方法的性能检测数据分析和可靠性评估基本框架	90

图 4-5 基于贝叶斯方法的性能检测数据分析的 OpenBUGS 实现.....	97
图 4-6 定位精度的性能检测数据.....	99
图 4-7 交叉验证点的性能演变预测值与观测值对比.....	103
图 4-8 剩余寿命和可靠性评估结果.....	104
图 5-1 多相关性能退化过程建模的框架.....	109
图 5-2 考虑动态环境与任务应力的多性能退化建模基本框架.....	110
图 5-3 基于贝叶斯方法的多性能退化分析的基本框架.....	117
图 5-4 基于数值积分的性能退化预测实现算法.....	123
图 5-5 基于数值积分的机床可靠性评估与剩余寿命预测实现算法.....	126
图 5-6 液压子系统性能退化和工作任务观测数据.....	127
图 5-7 主轴子系统性能退化和工作环境观测数据.....	128
图 5-8 主轴子系统和液压子系统对应性能退化增量的散点图.....	129
图 5-9 边缘退化增量对应累积概率分布函数取值的散点图.....	132
图 5-10 交叉验证点的性能退化预测值与观测值对比.....	133
图 5-11 最后一个观测点的预测值与观测值之间的相对误差.....	134
图 5-12 本文模型和简化模型在交叉验证点的性能退化预测值与观测值对比....	135
图 5-13 本文模型和简化模型剩余寿命估计值与实际值对比.....	136

表目录

表 2-1 用户厂收集的故障时间数据.....	37
表 2-2 考虑故障关联程度的重型镗铣床故障时间数据.....	38
表 2-3 完全维修假设下多个模型的拟合结果及模型选择的 AIC 值.....	40
表 2-4 模型和模型参数的估计结果.....	42
表 3-1 主轴系统的多源层次信息集的组成结构.....	70
表 3-2 主轴系统的层次独立客观信息集.....	70
表 3-3 主轴系统的层次覆盖客观信息集.....	71
表 3-4 主轴系统的多源层次主观信息集.....	71
表 3-5 模型参数的估计结果.....	74
表 3-6 主轴系统各层次节点可靠性评估结果.....	75
表 4-1 定位精度的性能检测数据.....	100
表 4-2 模型参数的估计结果.....	102
表 5-1 边缘退化过程模型参数的估计结果.....	131
表 5-2 高斯 Copula 函数模型参数的估计结果.....	133

主要符号及缩略语

T	故障发生时间的随机变量
ΔT	故障时间间隔的随机变量
M	模型变量
$\lambda(t)$	故障率函数
$\omega(t)$	故障强度函数
$F(t)$	不可靠度函数
$R(t)$	可靠度函数
$f(t)$	故障概率密度函数
θ	广义模型参数的集合
θ^F	广义固定模型参数的集合
θ^R	广义随机效应模型参数的集合
θ^H	广义超参数的集合
\mathbf{D}	广义的数据集
$L(\mathbf{D} \theta)$	数据集对应的似然函数
$\pi(M)$	模型的先验分布
$p(M \mathbf{D})$	模型的后验分布
$\pi(\theta)$	模型参数的先验分布
$p(\theta \mathbf{D})$	模型参数的后验分布
C	系统中的底层节点
S	系统中的高层节点
$\Psi(\bullet)$	系统的结构函数
$N^{P/F}$	系统中具有成败型数据的节点
$D^{P/F}$	成败型数据
N^{Life}	系统中具有寿命型数据的节点
D^{Life}	寿命型数据
N^{Deg}	系统中具有退化型数据的节点
D^{Deg}	退化型数据
$Y(t)$	性能退化过程
$\Delta Y(t)$	退化增量
$r(t)$	退化速率函数

$\Lambda(t)$	逆高斯过程模型的退化均值函数
\mathbf{Y}	性能退化数据
T^{RUL}	剩余寿命
$C(u_1, u_2, \dots, u_n)$	n 维 Copula 函数
$F(x_1, \dots, x_n)$	n 维随机变量 X_1, \dots, X_n 的联合累积概率分布函数
$B(\bullet)$	标准的布朗运动过程
$\phi(\bullet)$	标准正态分布的概率密度函数
$\Pr(\bullet)$	事件的概率
AIC	Akaike Information Criterion
BIC	Bayesian Information Criterion
BMA	贝叶斯模型综合方法 (Bayesian Model Averaging)
CDF	累积分布函数 (Cumulative Distribution Function)
MCMC	Markov Chain Monte Carlo
MTBF	平均故障间隔时间
NHPP	非齐次泊松过程 (Non-Homogeneous Poisson Process)
PDF	概率密度函数 (Probability Density Function)

第一章 绪论

1.1 研究背景和意义

数控机床作为装备制造业的“工作母机”，其性能水平的高低和质量的好坏是衡量一个国家制造业水平的重要标志^[1-3]。重型数控机床是数控机床中大系统构建、多技术集成和高质量保证的核心装备，肩负着航空航天、发电设备、大型船舶、轨道交通、海洋工程等行业关键产品和零部件的加工制造，属于高精尖的国家战略物质。重型数控机床技术水平的高低和质量的好坏已成为影响我国产业安全和国防安全的关键所在。

从产业安全的角度来看，《中国制造“2025”》中将制造业描述为“国民经济的主体，是立国之本、兴国之器、强国之基”^[4]。《中国制造“2025”》规划将数控装备列为“加快突破的战略必争领域”。数控装备是构建我国先进基础制造能力的坚实保证，只有基础制造能力得到确保之后，才有可能提升中国制造产品的附加值，才有机会提高中国制造业在国际制造业的分工层次和话语权。近年来，随着我国制造业转型升级的逐步开展，以中高端装备制造业为代表的具有高技术、高附加值的制造产业逐步与发达国家展开激烈竞争。诸如发电装备、工程机械装备、轨道交通装备等正瞄准国际高端市场奋力打入。这些高端装备的制造和生产无不依赖着重型数控机床在精度、效率、稳定性和可靠性上的保证，重型数控机床的技术和质量水平无疑成为影响制造业的关键所在。

从国防安全的角度来看，高端数控机床特别是重型数控机床对于制造先进的国防武器装备，具有超越经济价值的国防战略价值。当前国防武器装备中多数关键零部件由于材料、结构、尺寸、工艺等的特殊性，使得其加工制造难度极大，采用普通的数控机床和传统工艺无法满足其要求，此时重型数控机床成为制约先进国防武器装备发展的关键所在。万吨级自由锻造油压机、10万吨级模锻压机、超重型卧车、九轴五联动车铣复合中心等高档数控装备的成功研制，填补了我国在航空母舰、战略轰炸机、巨型火箭、核潜艇等武器装备研制中核心制造装备的空白，突破了发达国家对我国的技术封锁和限制，在这其中重型数控机床的重要性和决定性更是尤为突出。

21世纪以来，在《装备制造业调整和振兴规划》以及《国家中长期科学和技术发展规划纲要(2006-2020年)》等的支持下，我国重型数控机床取得了“从零到一”的突破，一批大吨位、大规格、重型和超重型数控机床的成功研制填补了我国关键工业领域的空白。这也使得我国航空航天装备、百万千瓦级发电装备、万

米深海石油钻探装备等一批重大技术装备取得了单机上的突破。然而在取得规模效应之后，重型数控机床却陷入了“大而不强”的局面——国产重型数控机床暴露出严重的可靠性问题：故障频发且无法追溯、性能波动且难以控制、整机可靠性衰退明显、关键功能部件可靠性低、维护成本高昂等。这些可靠性问题往往使得国产重型数控机床的高技术和高性能无法得到保障，从而导致依赖于重型数控机床的航空航天、发电设备、大型船舶、轨道交通、海洋工程等行业的发展受到限制，甚至影响到制造业的安全乃至国防安全。

造成国产重型数控机床可靠性较差的主要原因是行业内对重型数控机床的可靠性尚未进行系统深入的研究。重型数控机床刚完成了“从零到一”和“从小到大”的突破式发展。这些发展多以模仿、引进、技术消化和改进创新来完成，并且多以型号产品的研制和性能指标的的实现为目标，在快速发展中并未系统考虑机床的可靠性。现有的数控机床可靠性技术体系多是针对中小型数控机床而构建的。重型数控机床由于结构形式、制造装配、运动控制、任务工况、故障模式等方面均有别于中小型数控机床，导致现有的数控机床可靠性技术不能直接应用。针对重型数控机床的基础数据积累、可靠性试验、可靠性建模、可靠性评价、可靠性设计、可靠性增长以及可靠性考核验证等技术都十分缺乏甚至多为空白。此外，重型数控机床主机企业对可靠性工作的重视程度不够、可靠性人才不足、可靠性技术手段匮乏等，更是严重制约了重型数控机床可靠性工作的开展。重型数控机床可靠性技术体系的研究和应用，已经成为制约重型数控机床发展的关键所在。

在重型数控机床可靠性技术体系中，可靠性建模与评估是指根据重型数控机床在寿命周期各阶段可靠性信息的特点，结合机床的结构特征并考虑影响可靠性的多种因素，通过建立机床的可靠性模型来对其可靠性进行描述并对可靠性信息进行量化表征；在此基础上通过应用数据分析和信息处理来得到机床可靠性指标的点估计、区间估计和概率分布，以此对机床的可靠性进行定量描述和评价的过程。可靠性建模与评估是对机床在寿命周期内进行定量描述、监测和控制的必要手段，其主要目的是衡量机床的可靠性是否满足寿命周期各阶段的可靠性目标，检验机床的设计是否合理、工艺是否正确、使用是否得当，为机床设计的改进、工艺的优化、使用的保证以及机床整机可靠性的增长提供技术和信息支撑。作为重型数控机床可靠性技术体系中关键的基础共性技术，正确的可靠性建模是开展可靠性设计、可靠性试验和可靠性增长的前提，而精确的可靠性评估则是对数控机床进行定量控制、研制考核和健康管理的保障。在制造强国战略实施的大背景下，面对重型数控机床可靠性问题严峻的局面，重型数控机床可靠性建模与评估不可避免的成为重型数控机床可靠性体系构建首当其冲的研究要点和亟待解决的

应用难点。

在这样的政策背景和应用需求下，本文在国家自然科学基金“基于混合不确定性信息处理的复杂分层系统健康评估”(U13301055)、“高档数控机床与基础制造装备”科技重大专项课题“重型数控机床关键共性技术创新能力平台”的子课题“重型数控机床可靠性评价共性技术研究与应用”(2013ZX04013-011-05)等的资助下，开展重型数控机床可靠性建模与评估技术的研究，为重型数控机床可靠性关键共性技术的理论突破和应用实践提供技术基础和应用示例。

1.2 研究现状

重型数控机床的可靠性建模与评估技术由于应用对象的特殊性和关键性，对于工业发达的国家而言，其研究和应用已较为成熟且被视为企业的核心竞争力而秘不外宣；对于工业薄弱的我国而言，其研究和应用却属于起步和探索阶段。因此，关于重型数控机床的可靠性建模与评估技术的直接文献报道较少，但是考虑到重型数控机床的可靠性建模与评估属于可靠性评估理论研究的一个特定应用分支，可以通过对可靠性建模与评估理论的研究进展来把脉重型数控机床的可靠性建模与评估技术的研究现状。基于这样的考虑，下面首先对数控机床的可靠性建模与评估技术进行综述，然后在此基础上从广义的角度对可靠性建模与评估技术的三个方面进行综述：基于故障时间数据的可靠性建模与评估、基于多源层次信息集的可靠性建模与评估和基于性能退化数据的可靠性建模与评估。

1.2.1 数控机床的可靠性建模与评估

国外具体针对数控机床可靠性建模与评估的直接文献较少，而国内的文献报道相对丰富但多以基于故障时间数据的可靠性建模和评估技术的研究为主。下面分别按照国外和国内代表性的研究成果，来对数控机床的可靠性建模与评估进行概要综述。

美国 Merrick 等^[5]采用半参数的比例风险模型对数控机床的故障时间进行建模，并采用基于混合狄利克雷过程为先验分布的贝叶斯方法，对所建立的半参数模型进行参数估计和求解，以此实现数控机床可靠性的评估。Kharoufeh 等^[6]针对数控机床使用环境的复杂性，采用基于性能退化和状态空间的建模方法，分别建立了基于非齐次连续时间马尔科夫模型和有限状态齐次半马尔科夫模型的数控机床使用可靠性模型，在此基础上推导出相应模型下的使用寿命分布；然而，他们并未给出该模型下性能退化数据分析和可靠性评估的方法。德国 Verl 等^[7]提出一种基于无传感器信息的数控机床状态监测方法，通过将数控机床在运行期间的位

置信号（如位置、速度）与新数控机床的相应信号进行对比分析，以此来判断机床的健康状态并对机床的可靠性进行评估。日本 Mori 和 Fujishima^[8]介绍了一种基于远程状态监控的数控机床使用可靠性评估和维修决策方案。俄罗斯 Martinov 等^[9]提出了一种基于网络技术的数控机床远程控制和故障诊断的方法，以此实现对数控机床使用可靠性的评估及维修决策。

在国内，杨建国等^[10]针对数控机床现场故障时间的多台数、小样本、定时截尾的特点，基于似然比检验理论并应用两参数威布尔模型对数控机床进行建模，提出了数控机床可靠性指标的似然比检验两步区间减半评估方法。杨兆军等^[11]针对故障发生时序对可靠性建模评估的影响，从故障发生时间序列建模的角度，提出了基于故障发生时间的机床可靠性建模与评估方法。张根保等^[12]针对不完全维修条件下数控机床的可靠性评估，提出了一种对数线性比例强度模型，研究了基于极大似然和 Fisher 信息矩阵法的模型参数估计方法并对可靠性指标进行了点估计和区间估计。吴军等^[13]提出了一种基于非平稳自回归积分滑动平均模型的机床性能退化模型，采用隐马尔科夫链模型来对机床的运行状态进行识别推断，并在此基础上对机床的可靠性进行评估。邓超等^[14]从性能劣化的角度，采用隐马尔科夫模型对数控机床性能退化规律和健康状态转移的双重随机过程进行刻画，提出了一种基于多性能参数多观测序列的隐马尔科夫健康状态评估模型，并对隐马尔科夫模型的训练算法进行改进，以实现数控机床健康状态的评估。彭卫文等^[15]针对数控机床现场故障数据贫乏而大样本评估方法精度低的问题，结合数控机床在寿命周期各阶段可靠性评估的工程需求，提出了融合设计、研制和使用阶段多源寿命信息的系统可靠性评估方法。

张义民^[16-17]、杨兆军等^[18]以及张根保和王立平^[19]，对数控机床的可靠性建模与评估技术进行了综述。何正嘉等^[20]对机械设备可靠性评估时所面临的问题及国内外在该领域的研究方法进行了综述，提出了基于状态信息的可靠性评估方法。张小丽等^[21]对机械重大装备的寿命评估预测技术进行了综述，归纳了当前机械重大装备寿命评估预测研究在理论建模与试验中的若干问题。

1.2.2 基于故障时间数据的可靠性建模与评估

数控机床可靠性建模与评估技术的最初研究是继承了电子产品可靠性建模与评估技术的研究成果，以大样本故障时间数据的采集、建模和评价为基本研究路线^[11, 18-19]。Keller 等^[22]对 35 台数控机床运行 3 年间的故障数据，分别采用威布尔分布和对数正态分布进行建模分析，并对机床的 MTBF 进行估计。Jia 等^[23]对 24 台加工中心运行 1 年的故障数据，应用指数分布和威布尔分布进行了建模分析与

评估。Wang 等^[24]对 80 台数控车床 2 年内的故障时间数据,应用威布尔分布、对数正态分布、伽玛分布和指数分布进行了建模分析与评估。Wang 等^[25]和 Dai 等^[26]针对数控机床早期故障对应的故障时间数据,分别应用威布尔分布和对数正态分布对其进行建模分析和可靠性评估。这些基于故障时间数据的可靠性建模与评价方法都是在故障时间独立同分布的假设下开展的,主要涉及到故障时间数据模型及参数估计方法的研究,而当前研究最多的为威布尔分布及其拓展的模型系列^[27-30]。Murthy 等^[28]对威布尔分布系列模型的特性、参数估计、模型选择等进行了全面的描述。Pham 和 Lai^[30]对威布尔分布的拓展进行了综述。这些故障时间数据模型主要是用来对故障率曲线为浴盆曲线形式或者反浴盆曲线形式的产品进行可靠性建模描述。

近年来威布尔分布系列的故障时间数据模型主要从四个角度进行拓展:1) 威布尔分布故障率函数的改进。Bebbington 等^[31]提出了两参数的威布尔拓展模型 (Flexible Weibull Extension Distribution) 用来对故障率为单调递增和修正的浴盆曲线 (Modified Bathtub) 形式的产品进行可靠性建模。2) 多分布模型组合的构建。Sultan 等^[32]通过组合两个逆威布尔分布模型 (Inverse Weibull Distribution) 来提出一种新的寿命分布模型。Lu 和 Shi^[33]通过组合威布尔分布模型和泊松分布模型,来构建一种可以建模故障率曲线为单调递增、单调递减以及多种浴盆曲线形式的产品可靠性模型。3) 多部件系统可靠性函数的构建。Dimitrakopoulou 等^[34]利用多部件竞争失效的系统可靠性函数的形式建立了一种可以建模多种故障率曲线形式的产品可靠性模型。Carrasco 等^[35]和 Barriga 等^[36]采用类似的思路提出了两种故障时间数据模型。4) 广义贝塔函数变换 (Beta Generalized Function) 的构建。Silva 等^[37]、Paranaiba 等^[38]和 Singla 等^[39]分别将改进的威布尔分布模型 (Modified Weibull Distribution)、Burr XII 分布模型和广义威布尔分布模型 (Generalized Weibull Distribution) 通过广义贝塔函数的变换之后得到了故障时间数据建模能力更强的可靠性模型。这些故障时间数据模型的发展,主要以寿命周期故障率曲线的建模为主线,由以往的单调型故障率曲线的建模逐渐发展到浴盆曲线型、多特性的浴盆曲线型 (Upside-down, Unimodel 和 Modified 浴盆曲线等) 的建模。然而,以上所述的模型和方法都是以故障时间数据独立同分布为基本假设,在故障时间数据中存在关联关系时却难以适用,如最小维修 (Minimal Maintenance) 情形下产生的故障时间数据。

近年来随着对数控机床维修性的关注,考虑维修程度的故障时间数据建模和分析的研究逐渐展开。Merrick 等^[5]、王智明^[40]、许彬彬^[41]、张根保等^[42]、Yang 等^[43]分别应用半参数的比例失效模型、齐次泊松过程、非齐次泊松过程、Kijima I

型非完好维修模型、对数线性比例强度模型对数控机床考虑维修程度的故障时间序列建模和可靠性评估方法进行了研究。他们分别研究了完好维修（Perfect Maintenance）、非完好维修（Imperfect Maintenance）和最小维修情形下数控机床故障时间序列的建模和可靠性评估。

1.2.3 基于多源层次信息集的可靠性建模与评估

对于大型复杂装备系统级的故障时间数据往往难以获取，基于故障时间数据的可靠评估方法往往难以获得高置信度的评估结果^[45-46]。此时，通过综合系统中各层次的子系统、部件、零件的可靠性信息来对装备可靠性进行评估的方法，逐渐成为复杂装备系统可靠性建模与评估研究的突破口^[47-49]。

基于多源层次信息集的可靠性建模与评估，本质上是将不同信息来源并分布于不同系统层次的可靠性信息进行整体上的建模描述，并运用信息融合的方法将所有可用的信息都融合到系统的可靠性评估中，以完成对系统的可靠性建模与评估。Mastran^[49]提出应用贝叶斯方法将分布在系统不同层次的成败型试验数据进行融合，以实现系统可靠性的评估。Mastran 和 Singpurwalla^[50]、Barlow^[51]、Martz 等^[52]以及 Martz 和 Waller^[53]进一步研究了不同系统结构和不同层次数据形式下的多源层次信息建模与评估方法。他们的工作初步奠定了基于多源层次信息集的可靠性建模与评估的基础，并主要应用于多层次的成败型和寿命型可靠性数据的可靠性建模与评估。然而，受到贝叶斯方法中后验分布求解算法的限制，在模型的计算和求解中主要采用近似求解的方法，这使得这些模型和方法的建模能力和评估精度都受到了较大的限制。

随着马尔科夫链蒙特卡洛方法的提出和应用^[55-57]，基于贝叶斯方法的多源层次信息集的可靠性建模与评估在算法实现上得到了基本保证。Johnson 等^[57]应用层次贝叶斯方法构建了融合系统不同层次的成败型试验数据的可靠性建模与评估方法，为基于层次贝叶斯方法的多源层次信息集的建模与评估奠定了基础。Hamada 等^[58]研究了以故障树为建模工具的多源层次信息的融合评估方法，并在此基础上研究了多源层次信息融合评估在系统可靠性优化分配中的作用。Graves 和 Hamada^[59]、Anderson-Cook 等^[60]和 Shane Reese 等^[61]分别研究了融合性能退化型、成败型和寿命型数据的可靠性建模与评估方法。这些方法都是基于多源层次信息客观数据集的可靠性建模与评估方法，并且多以多源层次的成败型或寿命型数据集为主。为了解决复杂系统所面临的信息来源多样和多种不确定性共存下的问题，Wilson 等^[62]和 Anderson-Cook 等^[63]研究了融合层次主客观信息集的可靠性建模与评估方法。Jackson 和 Mosleh^[64]提出了多源层次信息集中存在信息相互覆盖

(Overlapping Data)情形时的可靠性建模与评估方法。Guo 和 Wilson^[65]以及 Peng 等^[66]进一步将多源信息融合的方法拓展到多种信息来源、多种数据类型(成敗型、寿命型和退化型)以及主客观信息共存情形下的复杂装备可靠性建模与评估中,使得多源层次信息集的可靠性建模与评估方法适用范围更广,并且经过建模和评估处理之后的可靠性信息量化更全面。

1.2.4 基于性能退化数据的可靠性建模与评估

性能退化是指产品的某一性能指标由于内在的物理或者化学过程而表现出来的性能指标随时间变化的过程。对于多数产品而言性能指标的退化往往与内在的故障机理相关联,如电子元器件电性能指标的退化、机械零部件的磨损、金属材料的疲劳裂纹增长等。这使得从产品的性能退化过程来研究产品的故障并对产品的可靠性进行建模与评估成为可能^[68-69]。

近年来,随着诸如故障物理理论、传感器技术和信息技术的发展,基于性能退化数据的可靠性建模与评估技术逐渐发展起来并成为研究热点^[71-74],其研究现状可归纳为以下四个方面:

(1) 根据性能退化试验数据建模分析外推系统可靠性^[75-82]。Lu 和 Meeker^[75]采用非线性影响模型来对性能退化数据进行建模,并推导出了相应的故障时间分布,以此来实现故障时间数据缺乏情形下的产品可靠性评估。Whitmore 和 Schenkelberg^[76]采用时间尺度变化方法和维纳过程模型对加速退化试验数据进行建模分析,以此来对产品的可靠性进行评估。Wang 等^[77]将该模型进行了应用研究。Park 和 Padgett^[79-81]研究了采用几何布朗运动过程和伽马过程来进行加速退化试验建模以及产品可靠性评估的方法。与此同时,Bae 等^[81]研究了多种性能退化数据模型下产品寿命分布模型的推导方法及其性质。

(2) 根据性能退化试验数据和使用环境应力外推系统可靠性^[83-88]。Liao 和 Elsayed^[85]针对试验工况环境与实际工况环境之间存在差异性的问题^[87],将实际工况下的环境应力作为加速退化模型中的加速因子引入可靠性的评估模型中,提出了一种应用加速退化试验数据并考虑使用环境应力影响的可靠性评估方法。Bagdonavičius 和 Nikulin^[86]通过将协变量引入加速寿命模型和性能退化模型中,进一步研究了考虑使用环境应力影响的可靠性试验数据建模方法。

(3) 根据使用阶段状态监测信息评估系统可靠性^[89-92]。Gebrael 等^[89]针对产品剩余寿命可靠性评估中状态监测信息动态变化的特点,提出了一种基于贝叶斯方法的产品剩余寿命实时评估方法。随后基于状态监测信息的产品剩余寿命得到了广泛的研究,Si 等^[90]对基于状态监测信息的剩余寿命评估方法进行了综述。最

近, Chen 和 Tsui^[91]考虑性能退化过程的阶段性和剩余寿命评估点之间的相关性, 提出了一种两阶段退化阈值模型并对贝叶斯估计方法进行了算法上的改进, 以实现剩余寿命高精度的评估。

(4) 根据可靠性试验信息和状态监测信息评估系统可靠性^[93-96]。Gebrael 和 Pan^[92]针对动态工况环境下产品剩余寿命评估问题, 在贝叶斯信息融合框架下, 研究构建了一种融合性能退化试验数据和状态监测数据的方法以实现剩余寿命进行高精度的评估。与此同时, Meeker 等^[93]针对产品使用环境信息缺失的情形, 提出了一种关联加速寿命试验和现场故障数据的现场可靠性建模评估方法。Wang 等^[94]通过引入校准系数 (Calibration Factor) 来刻画试验环境和工况环境的差异, 在此基础上应用贝叶斯方法构建了融合加速退化试验数据和现场性能退化数据的使用可靠性评估方法。Liao 和 Tian^[95]考虑使用环境中的时变因素对产品剩余寿命的影响, 提出了一种加速退化试验和状态监测信息的融合框架, 并以此来对单个产品在时变使用环境下的剩余寿命进行评估。Peng 等^[88]提出了一种综合性能退化试验和状态监测的建模方法, 通过将随机影响模型、动态协变量和描述工况环境信息的标记过程 (Marker Process) 逐步引入到基本的性能退化过程模型中, 来依次构建性能退化试验对应的退化过程模型和状态监测对应的性能退化过程模型, 为可靠性试验信息和状态监测信息的融合提供了模型基础。

1.2.5 综述总结与问题提出

可靠性建模与评估技术的发展随着寿命周期可靠性工程技术、数据采集技术以及信息处理方法的发展而不断演进。可靠性建模与评估技术作为围绕数据建模分析而展开的寿命周期多阶段的共性技术, 其发展演进从数据类型的角度来看涵盖了故障时间数据、多源层次信息和性能退化数据等多种数据类型; 从寿命周期的角度来看囊括了设计阶段以整体指标把握为关注点的概要评估, 研制阶段以设计指标实现为关注点的全面评估, 使用阶段以功能稳定保证为关注点的实时评估。重型数控机床由于具有结构功能复杂、故障模式多样、影响因素繁多、小批量定制且实时评估要求高等特征, 使得其对应的可靠性建模与评估具有如下特点:

(1) 设计阶段重型数控机床可靠性工作的开展, 首要任务是对重型数控机床的可靠性进行摸底。这就需要从同类型机床的售后维修记录或者现场使用记录中挖掘故障时间数据来对机床的整体可靠性水平进行建模评估。常规的基于故障时间数据的可靠性建模与评估技术, 多以独立同分布为基本假设并着重于不同形式的概率分布模型的研究。对于重型数控机床而言, 其故障时间数据的产生一方面与机床内在的可靠性直接相关, 另一方面也受到环境、使用和维修等因素的影响,

这使得其故障时间数据并非独立同分布，并且难以采用单一概率分布模型对其进行全面建模。因此，亟需研究针对重型数控机床考虑故障关联程度、维修程度以及模型不确定性的故障时间数据建模与评估技术。

(2) 研制阶段重型数控机床可靠性工作的开展，需要重点保证机床可靠性设计指标的实现，这就需要将机床各零件、部件、子系统和系统的可靠性进行整体上把握，使得融合多源层次信息的可靠性评估技术成为关键。常规的基于多源层次信息集的可靠性建模与评估技术多是建立在贝叶斯方法的基础之上，这使得数据结构形式受到了较大的限制。重型数控机床的多源层次信息集不仅包含了成败型、寿命型和退化型的多源层次客观数据，同时也包含了存在着信息覆盖、主客观信息共存的多源层次主客观信息。此时，需要将基于贝叶斯方法的可靠性建模与评估技术进一步拓展，以应对重型数控机床多源层次信息集中形式的多样性、数据的覆盖性以及信息的主客观共存性所带来的问题和挑战。

(3) 研制阶段末期和使用阶段初期是重型数控机床可靠性工作开展比较特殊的时期，重型数控机床由于研制周期长、合同经费高、考核指标多、故障成本大等特性而导致其验证交付难度大，主机厂和用户厂需要协同展开可靠性建模与评估的工作，这使得基于性能检测数据的可靠性建模与评估成为首要应用技术。基于性能检测数据的可靠性建模与评估可以借鉴现有的性能退化建模与可靠性评估方法。在常规的基于性能退化数据的可靠性建模与评估技术中，性能退化模型所描述的退化轨迹往往较为单一，并且难以应对重型数控机床同型号同批次中个体差异性和性能波动性等问题。因此，需要针对重型数控机床性能演变过程轨迹的多样性来研究对应的模型，并且在此基础上针对主机厂和用户厂协同验证评价的需求，重点研究综合主机厂和用户厂性能检测数据的评估方法。

(4) 使用阶段重型数控机床可靠性工作的核心是保证机床的使用可靠性并降低用户厂的总体拥有成本 (Total Ownership Cost)。这就需要实时地对重型数控机床的可靠性进行评估以准确把握其维修时机和剩余寿命，这使得基于状态监测数据的可靠性建模与评估方法成为必须。现有的基于状态监测数据的可靠性建模与评估技术多以单一性能退化指标的建模分析为主，并且没有明确的将影响机床使用可靠性的环境应力和工作应力引入到建模与评估中去。对于重型数控机床而言，由于其使用阶段性能指标的多样、环境和工作应力的动态多变以及状态监测数据的部分缺失，这使得常规的基于单一性能退化指标和简单工作应力的状态监测数据建模与评估方法难以适用。因此，亟需针对重型数控机床的多性能退化、动态因素影响以及监测数据部分缺失等关键问题展开进一步的研究。

1.3 论文的研究内容和结构

1.3.1 论文的研究内容

针对重型数控机床寿命周期各阶段中可靠性工作存在的诸多研究问题与应用挑战, 本文拟在可靠性建模与可靠性评估方面展开研究。在“高档数控机床与基础制造装备”科技重大专项课题“重型数控机床关键共性技术创新能力平台”的子课题“重型数控机床可靠性评价共性技术研究与应用”的驱动下, 以重型数控机床在寿命周期多个阶段所呈现出来的实际问题为主线, 根据广义的可靠性建模与评估技术的研究发展路线为引导, 重点对重型数控机床基于故障时间数据、基于多源层次信息集、基于性能检测数据和基于状态监测数据的可靠性建模与评估进行研究, 主要内容如下:

(1) 基于故障时间数据的重型数控机床可靠性建模与评估

基于故障时间数据的可靠性建模与评估多为设计阶段的整体摸底所采用, 其对应的故障时间数据往往受到故障关联程度和机床的维修程度的影响, 而难以采用常规假设下的模型来进行建模分析; 并且受到现有模型建模能力的局限, 对于重型数控机床故障时间数据的建模需要综合多个模型的评估结果。本文拟通过研究重型数控机床故障时间数据的特性, 在现有故障时间数据模型的基础上, 研究考虑故障关联程度和维修程度的故障时间建模方法, 并将贝叶斯模型综合方法引入到故障时间数据的建模分析中, 通过多个模型的分析结果综合来对重型数控机床的可靠性进行评估。

(2) 基于多源层次信息集的重型数控机床可靠性建模与评估

基于多源层次信息集的可靠性建模与评估多在研制阶段采用, 其对应的多源层次信息集往往表现出数据形式多样、层次信息覆盖和主客观信息共存等特性。本文拟通过贝叶斯方法和贝叶斯网络的综合, 来构建重型数控机床基于多源层次信息集的可靠性建模与评估方法。利用层次贝叶斯方法来处理独立来源的具有多种数据形式的多源层次数据集, 以保证对大量数据的高效建模与融合。利用贝叶斯网络方法来处理相关来源和主客观信息共存的多源层次信息集, 以保证主客观信息的准确融合, 并在此基础上对机床的可靠性进行有效的评估。

(3) 基于性能检测数据的可靠性建模与评估

基于性能检测数据的可靠性建模与评估往往在研制阶段的末期与使用阶段的初期所采用, 其对应的性能检测数据往往表现出性能演变轨迹形式多样并且具有明显的个体差异性和性能波动性, 同时也需将主机厂和用户厂的性能检测数据进行融合来对机床的可靠性进行协同评估。本文拟将性能演变速率模型引入到性能

演变过程模型中，通过建立不同速率模型来将现有性能演变过程模型进行改进，以实现多种性能演变轨迹形式的描述。在此基础上将随机效应模型引入到所建立的性能演变过程模型中，来对个体差异性和性能波动性进行建模描述。在此基础上，借助贝叶斯性能退化分析方法的思路，进一步研究融合主机厂与用户厂性能检测数据的可靠性评估方法，从而实现对现有性能演变过程模型的改进与可靠性评估方法的拓展。

(4) 基于状态监测数据的可靠性建模与评估

基于状态监测数据的可靠性建模与评估主要在使用阶段所采用。使用阶段的可靠性建模与评估往往面临着多性能指标退化、环境与工作应力动态影响和状态监测数据部分缺失等问题。这使得其一方面需要解决动态环境与任务应力下多性能退化相关建模与分析的关键问题，另一方面需要满足不完全状态监测数据下机床性能退化预测、剩余寿命评估以及结果不确定性表征的实际需求。本文拟通过单性能退化模型和 Copula 函数来构建多性能退化过程模型，并且通过协变量将动态环境工作应力进行建模引入。在此基础上，进一步研究基于贝叶斯方法的多性能退化分析方法，并结合 Copula 函数的性质提出缺失观测点性能退化预测以及机床剩余寿命评估的方法。

1.3.2 论文的总体结构

本论文共分为七章，围绕着重型数控机床可靠性建模与评估核心问题依次展开研究。本文的总体框架如图 1-1 所示，章节的组织以重型数控机床寿命周期可靠性建模与评估的需求为主线来贯穿。

各章的具体内容概述如下：

第一章为绪论，主要介绍研究的背景、意义和现状，并概要描述论文的研究内容和总体结构。

第二章将针对机床设计阶段的数据特性与评估需求，研究考虑故障关联程度、维修程度和模型不确定性的故障时间数据建模与机床可靠性评估方法。

第三章将针对机床研制阶段的数据特性与评估需求，构建一种综合贝叶斯方法与贝叶斯网络的多源层次信息建模与机床可靠性评估方法。

第四章将针对机床验证交付阶段的数据特性与工程需求，提出应对轨迹形式多样的性能演变过程模型，并研究融合主机厂与用户厂性能检测数据的可靠性评估方法。

第五章将针对机床使用阶段的数据特性与实时需求，提出一种考虑动态工况环境应力的多性能退化模型，并在此基础上研究不完全状态监测数据下的性能退

化预测与剩余寿命实时评估方法。

第六章将系统总结全文，并概要展望以后的研究工作。

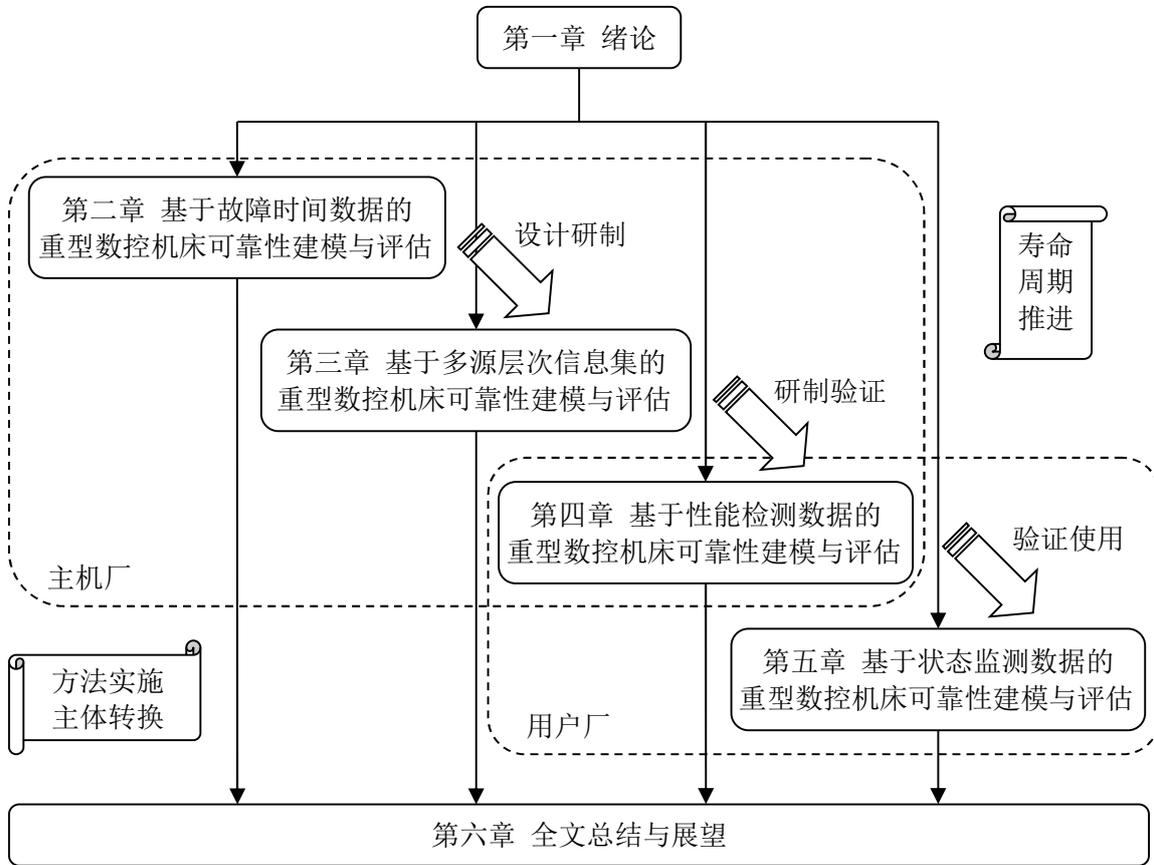


图 1-1 论文的总框架图

第二章 基于故障时间数据的重型数控机床可靠性建模与评估

故障时间数据由于采集方式直观、建模难度较小并且研究成果较多，在产品的可靠性评估中经常被使用。多数基于故障时间数据的可靠性建模与评估方法是建立在故障间隔时间独立同分布的假设之上。对于批量较大、故障模式单一的不可修产品，应用这些方法能够得到较好的评估结果。然而，对于重型数控机床这类小批量定制、故障模式繁多的可修产品而言，建立在故障间隔时间独立同分布假设上的模型和方法往往难以适用。重型数控机床故障时间一方面受到维修程度的影响，另一方面也受到故障关联程度的影响。在进行故障时间数据建模时需要在这两个方面进行妥善处理，同时也需考虑故障数据模型的不确定给评估结果带来的影响。本章将在现有可靠性建模与评估方法的基础上，开展考虑故障维修程度、故障关联程度和模型不确定的故障时间数据建模和可靠性评估方法的研究，为重型数控机床基于故障时间数据的可靠性评估提供技术支撑。

2.1 引言

数控机床可靠性建模与评估方法的最初研究继承了电子产品可靠性建模与评估方法的研究成果，以大样本故障时间数据的采集、建模和评价为基本思路和路线^{[18][19]}。Keller 等^[22]对 35 台数控机床进行了为期 3 年多的故障数据收集，并分别采用威布尔分布和对数正态分布，对收集到的故障间隔时间数据进行建模分析，得到了机床的可靠性模型和 MTBF 的估计。他们用威布尔分布对机床首次故障、第二次故障和第三次故障的故障时间数据进行建模分析，同时也将所有的故障时间数据在独立同分布的假设下，分别用威布尔分布和对数正态分布进行了建模分析。在他们的分析结论中，当对故障时间数据按故障发生的次序（首次、第二次和第三次）分别进行建模时，威布尔分布能够对数据进行较好的描述；而当把所有的数据按照独立同分布的假设时，对数正态分布却能够对数据进行较好的描述。Wang 等^[24]研究了数控车床的可靠性建模问题，他们在故障时间数据独立同分布的假设下，分别应用威布尔分布、对数正态分布、伽玛分布和指数分布对 80 台数控车床 2 年内的故障时间数据进行了建模分析。为了解决模型的选择问题，他们应用了模糊综合评判的方法，最后得出对数正态分布模型是最适合建模这些数控车床故障时间数据的概率分布模型。在以上研究工作的基础上，数控机床的故障时间数据建模与可靠性评估的研究多以故障间隔时间独立同分布为基本假设，并应用威布尔分布和对数正态分布来对数据进行建模分析^{[25][26]}。

近年来随着对数控机床维修性的关注，考虑维修程度的故障时间数据建模和分析的研究逐渐展开^[40-44]。这些方法和模型的提出一方面完善了数控机床可靠性工程方法和技术体系，另一方面为数控机床可靠性建模和评估提供了丰富的选择。然而，当众多模型都可对故障时间序列进行建模时，如何将模型的不确定性引入到机床的可靠性建模与评估中却没有得到深入的研究。特别是对于重型数控机床，由于其结构功能复杂、故障模式繁多、产品样本量少和可靠性影响因素多等特征，在基于故障时间数据的可靠性建模与评估中，往往会遇到故障数据不充分、维修程度和故障关联程度不明确以及模型选择难确定等问题。因此，重型数控机床基于故障时间数据的可靠性建模与评估，需要针对这些特征和问题展开深入研究。

2.2 重型数控机床的故障时间数据

故障时间数据是重型数控机床进行可靠性建模和评估的首要数据类型。由于重型数控机床结构复杂、故障多样，使得故障时间数据的获取在保证数据准确性和完整性方面存在较大的挑战。在开展基于故障时间数据的可靠性建模与评估时，首先需要对故障时间数据的来源和特性进行全面的分析，以把握重型数控机床故障时间数据分析的关键点。

(1) 故障时间数据的主要来源及其特性

重型数控机床故障时间数据获取的途径主要包括：主机厂的售后维修数据、主机厂的可靠性试验数据和用户厂的现场使用数据。主机厂的售后维修数据主要包括多台同型号重型数控机床在售后维修期内的故障时间数据，是主机样本量较大的数据来源。然而，售后维修数据多以用户难以独立解决的故障记录为主，对于维修难度较小的故障，用户多自行维修解决而导致记录不全甚至记录缺失；并且由于售后维修人员的主要关注点是机床维修的方式和维修的结果，而对于故障时间相关信息的记录较为粗略。主机厂的售后维修数据可用来分析重型数控机床早期的故障特性，其对重型数控机床设计水平和制造工艺的考核验证以及首次故障时间的分析和评估具有重要意义。

主机厂的可靠性试验数据主要包括整机的寿命试验数据和关键功能部件的台架可靠性试验数据，是数据准确性和完整性都较高的数据来源。然而，重型数控机床由于受到其体积庞大、结构复杂、制造装配难度大等特性的限制，使得其整机和功能部件可靠性试验成本高昂、技术难度大甚至难以执行。并且多数可靠性试验都是嵌入在性能试验中开展的，主机厂往往在试验中人为的避免故障的发生，这使得可靠性试验数据在样本量上受到限制。主机厂的可靠性试验数据可用来评价机床在给定的环境条件和任务工况下主机和关键功能部件的可靠性，其对机床

设计改进和制造工艺提升以及整机和关键功能部件的可靠性评估意义显著。

用户厂的现场使用数据主要包括整机的日常运行记录、故障维修记录和保养维护记录，是数据信息量较大的数据来源。然而，用户厂的现场使用记录的有效性，随着用户厂机床管理水平和机床的拥有量的差异而存在着较大的差别。对于大型装备制造企业，如中信重工机械股份有限公司、二重集团（德阳）重型装备股份有限公司和中国东方电气集团公司，由于重型数控机床是企业的当家把关装备，对其使用维修信息记录较为完整。在这些用户厂的现场使用数据中记录的信息多为从用户厂的角度来记录的故障信息，任何影响机床运行的故障信息都予以了记录。这些记录并未区分故障是否为关联故障，即该故障是否由机床的设计、制造、材料和零部件等本身的缺陷和问题所导致的故障。主机厂的现场使用数据可用来评价机床在实际工况下的可靠性，其对重型数控机床的可靠性评估以及机床的运行维护和健康管意义显著。

（2）故障关联程度与故障时间数据的关系

根据国标 GB/T23567.1-2009，故障定义为“产品不能执行规定功能的状态”。在此基础上，结合重型数控机床的特性可将其故障判定原则确定如下：

1) 如果有一个或者若干性能指标超过了规定界限则判定为故障。

2) 如果出现了一个或者若干子系统、功能部件或零部件损坏或失效，而导致无法完成规定的功能则判定为故障。

重型数控机床结构功能的复杂性和故障模式的多样性，使得其发生故障的原因多种多样，其中有些故障是在建模分析的过程中必须计入的，而有些故障是需要予以排除的。这就涉及到故障分析中的故障计数问题，也即故障的关联程度问题。基于国标 GB/T23567.1-2009 中的故障判定原则，考虑重型数控机床的特性，将其故障关联程度的判定原则确定如下：

1) 关联故障是指那些由重型数控机床本身原因而引起的，在进行可靠性建模与评估时必须计入的故障。重型数控机床常见的关联故障主要包括：由于设计、制造、装配等引起的故障，由于零部件、元器件、软件等引起的故障，由于耗损件在寿命期内的故障所引起的故障等。

2) 非关联故障是指那些不是由数控机床本身原因引起的，而是由外在因素所造成的，在进行可靠性建模与评估时必须予以排出的故障。重型数控机床常见的非关联故障主要包括：安装不当引起的故障、误操作故障、维修不当引起的故障、环境条件超出允许条件引起的故障、工作应力超出允许应力引起的故障等。

在进行基于故障时间数据的可靠性建模与评估中，某一故障所对应的故障时间点是否计入到可靠性建模与评估中需要考虑该故障是否为关联故障。对于重型

数控机床而言，由于影响其可靠性的因素繁多，包括设计、制造、材料、零部件、环境、工况等。这些因素涉及到主机厂的设计、研制与制造环节，以及用户厂的使用与维护环节。某个故障的产生往往包含多个因素的共同作用，一方面可能来自于主机厂设计与制造环节的问题，同时也涉及到了用户厂的使用与维护的不足，这些往往使得故障的关联程度难以进行准确的判定。如果将非关联故障所对应的故障时间数据计入到可靠性建模与评估中，将会导致评估得到的机床可靠性比实际情况低；相反，如果将关联故障所对应的故障时间点作为非关联故障予以排除，将会导致评估结果偏高。因此，在基于故障时间数据的可靠性建模与评估中，需要妥善处理好故障关联程度界定的问题。

(3) 故障维修程度与故障时间数据的关系

重型数控机床属于可修产品，由于结构庞大、功能复杂和故障模式多等特点，其故障后的维修往往难以达到“修复如新”（完好维修）的效果。多数故障后的维修都是使重型数控机床回到故障之前的状态，即“修复如旧”（最小维修）；或者达到比故障之前的状态较好却比全新状态较差的状态，即非完好维修。

在进行基于故障时间数据的可靠性建模与评估中，某一故障所对应的故障时间点在可靠性建模与评估中的模型表达，需要考虑该故障对应的时间序列是在怎样的维修情形下产生的。重型数控机床的维修多以最小维修为主，这使得现有完好维修假设下的可靠性模型与评估方法难以适用。

当考虑维修程度的影响时，故障时间数据可以采用两种形式来进行建模：故障间隔时间数据和故障发生时间序列数据。对于修复如新情形下的可修产品，主要是通过故障间隔时间数据的收集和分析，来对产品的可靠性进行建模与评估。对于非完好维修假设情形下的可修产品，主要是通过故障发生时间数据（序列）的收集和分析，来对产品的可靠性进行建模与评估。对于完好维修情形下的故障时间序列分析，可等同为独立同分布情形下的故障间隔时间数据的分析，此时故障发生的序列关系不会对模型的建立和评估的结果产生影响。对于非完好维修和最小维修情形下的故障时间序列分析，则需要对整个时间序列进行建模分析，此时故障发生的顺序是影响建模成败和评估优劣的关键所在。由于故障的维修程度往往难以进行明确的判定，简单的采用完好维修情形下的模型来开展可靠性建模与评估，将会使评估结果与实际可靠性水平之间存在较大的偏差。并且，维修程度的差别将会使得所采用的可靠性模型存在较大的差别，模型不确定性问题也与其相互耦合。因此，在基于故障时间数据的可靠性建模与评估中，需要妥善处理好维修程度和模型不确定的问题。

2.3 重型数控机床故障时间数据的建模

重型数控机床的故障时间数据的可靠性模型，随着维修程度的不同需要对应采用不同的故障数据模型；同时故障关联程度的难以确定，将会使得故障时间数据在对应模型下的表达需要进行适应性调整；而模型不确定性问题，使得故障时间数据的建模需要在所有潜在可能的模型下进行权衡。本节将对这三个方面的问题进行一一研究。

2.3.1 考虑维修程度的故障时间数据建模

维修程度的差别使得故障时间数据的模型存在着更新过程、非齐次泊松过程和 Kijima 型非完好维修模型的差别，这些模型都是针对故障时间序列数据的模型。本章所研究的故障时间序列数据为来自对 n 台重型数控机床的观测数据，如图 2-1 所示。第 i ($i=1, \dots, n$) 台重型数控机床的故障时间序列描述为：该型机床从 $T_0=0$ 时刻开始运行，在观测时间内获得了一组样本量为 m_i 的故障时间点序列 T_{ij} ($j=1, \dots, m_i$)，与之对应的故障间隔时间为 $\Delta T_{ij} = T_{ij} - T_{i,j-1}$ 。

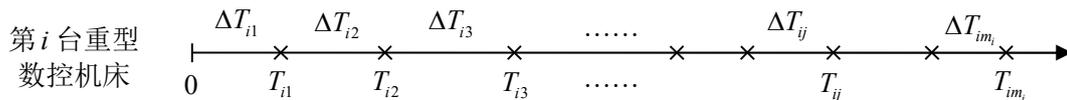


图 2-1 故障时间序列数据

2.3.1.1 完好维修下的故障时间数据建模

在完好维修情形下，机床每次故障后的维修都达到了“修复如新”的效果，这意味着相邻故障的间隔时间 ΔT_{ij} 为独立同分布的随机变量序列。因此，可通过对故障间隔时间 ΔT_{ij} 的建模来研究完好维修情形下故障时间数据的可靠性建模方法。根据故障时间数据分布特性的不同，可以选用不同的分布函数来对其进行建模。对于重型数控机床这类复杂系统，常用的分布函数主要包括威布尔分布、对数正态分布和伽玛分布。由于这些模型的主要差别在于故障率函数 $\lambda(\Delta t)$ 的表达形式不同，下面在不具体化故障率函数的情形下，给出完好维修下重型数控机床故障时间数据模型的一般形式。

当采用故障率函数为 $\lambda(\Delta t)$ 所对应的分布函数建模时，第 i 台重型数控机床故障间隔时间 ΔT_{ij} 的分布函数、概率密度函数以及平均故障间隔时间 (MTBF) 分别为：

$$F^{Per}(\Delta t_{ij} | \theta_i^{Per}) = 1 - \exp\left(-\int_0^{\Delta t_{ij}} \lambda_i(u | \theta_i^{Per}) du\right) \quad (2-1)$$

$$f^{Per}(\Delta t_{ij} | \boldsymbol{\theta}_i^{Per}) = \lambda_i(\Delta t_{ij} | \boldsymbol{\theta}_i^{Per}) \exp\left(-\int_0^{\Delta t_{ij}} \lambda_i(u | \boldsymbol{\theta}_i^{Per}) du\right) \quad (2-2)$$

$$\begin{aligned} \text{MTBF}_i^{Per} &= E(\Delta T_{ij} | \boldsymbol{\theta}_i^{Per}) = \int_0^{\infty} \Pr(\Delta T_{ij} > t) dt \\ &= \int_0^{\infty} \exp\left(-\int_0^t \lambda_i(u | \boldsymbol{\theta}_i^{Per}) du\right) dt \end{aligned} \quad (2-3)$$

式中， $\boldsymbol{\theta}_i^{Per}$ 为第 i 台机床对应的故障间隔时间分布模型的参数，也是故障率函数 $\lambda_i(\Delta t | \boldsymbol{\theta}_i^{Per})$ 的参数。

在实际工况中，由于重型数控机床会受到制造、装配、使用和维护阶段多因素的影响而存在个体差异性，同型号的机床可能具有不同的故障率特性和不同的特征寿命。为了对这种个体差异性进行建模，本文将随机效应（Random Effect）模型引入到模型参数 $\boldsymbol{\theta}_i^{Per}$ 中。此时， $\boldsymbol{\theta}_i^{Per}$ 被划分为 $\{\boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R\}$ ，其中 $\boldsymbol{\theta}^F$ 为 n 台机床中取值相同且与机床个体差异性无关的模型参数（固定参数）， $\boldsymbol{\theta}_i^R$ 为所有机床共有但是取值存在个体差异性的模型参数（随机参数）。通过进一步将参数 $\boldsymbol{\theta}_i^R$ 描述为具有概率密度 $f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HR})$ 的随机变量，使得每一台机床中与个体差异性相关的模型参数都是该随机变量的一组样本实现，这样即可完成考虑个体差异性的故障时间数据的建模。在这些可用于随机参数 $\boldsymbol{\theta}_i^R$ 建模的分布模型中，常用的概率分布模型有截尾正态分布、伽玛分布、对数正态分布和贝塔分布等。此时， $f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HR})$ 中的 $\boldsymbol{\theta}^{HR}$ 为随机参数 $\boldsymbol{\theta}_i^R$ 对应概率分布的超参数（Hyper-parameter）。

此时，式(2-1)至(2-3)描述的是考虑个体差异性的机床各个个体故障间隔时间的分布函数、概率密度函数以及 MTBF。对于机床样本总体的相应函数以及 MTBF 的表达式，可借助于随机效应参数 $\boldsymbol{\theta}_i^R$ 的概率分布表示为：

$$F^{Per}(\Delta t | \boldsymbol{\theta}^F, \boldsymbol{\theta}^{HR}) = \int_{\boldsymbol{\theta}_i^R} \left(1 - \exp\left(-\int_0^{\Delta t} \lambda_i(u | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) du\right)\right) f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HR}) d\boldsymbol{\theta}_i^R \quad (2-4)$$

$$f^{Per}(\Delta t | \boldsymbol{\theta}^F, \boldsymbol{\theta}^{HR}) = \int_{\boldsymbol{\theta}_i^R} \lambda_i(\Delta t | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) e^{-\int_0^{\Delta t} \lambda_i(u | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) du} f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HR}) d\boldsymbol{\theta}_i^R \quad (2-5)$$

$$\text{MTBF}^{Per} = \int_{\boldsymbol{\theta}_i^R} \int_0^{\infty} \exp\left(-\int_0^t \lambda_i(u | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) du\right) f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HR}) dt d\boldsymbol{\theta}_i^R \quad (2-6)$$

在此基础上，故障间隔时间数据 $\Delta \mathbf{t} = \{\Delta t_{ij}, i = 1, \dots, n, j = 1, \dots, m_i\}$ 所包含的机床可靠性信息，则可通过该数据集的似然函数描述为：

$$L^{Per}(\Delta \mathbf{t} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^{HR}) = \prod_{i=1}^n f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HR}) \prod_{j=1}^{m_i} f^{Per}(\Delta t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) \quad (2-7)$$

式中， $\boldsymbol{\theta}^R = \{\boldsymbol{\theta}_i^R, i = 1, \dots, n\}$ 包含了所有样本的随机效应参数 $\boldsymbol{\theta}_i^R$ ， $f^{Per}(\Delta t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R)$ 为

式(2-2)描述的概率密度函数。

对于完好维修下不考虑个体差异性的机床故障间隔时间数据的建模, 式(2-1)至(2-3)中所有个体的随机参数将不复存在, 可用总体的模型参数 $\boldsymbol{\theta}^{Per}$ 代替 $\boldsymbol{\theta}_i^{Per}$ 来进行表达, 即 $\boldsymbol{\theta}_1^{Per} = \boldsymbol{\theta}_i^{Per} = \boldsymbol{\theta}_n^{Per} = \boldsymbol{\theta}^{Per}$ ($i = 1, \dots, n$)。在此情形下, 故障间隔时间数据 $\Delta \mathbf{t} = \{\Delta t_{ij}, i = 1, \dots, n, j = 1, \dots, m_i\}$ 的似然函数可表述为:

$$L(\Delta \mathbf{t} | \boldsymbol{\theta}^{Per}) = \prod_{i=1}^n \prod_{j=1}^{m_i} f^{Per}(\Delta t_{ij} | \boldsymbol{\theta}^{Per}) \quad (2-8)$$

式中, $f^{Per}(\Delta t_{ij} | \boldsymbol{\theta}^{Per})$ 为式(2-2)描述的模型参数取 $\boldsymbol{\theta}^{Per}$ 的概率密度函数。

对于故障率 $\lambda(\Delta \mathbf{t} | \boldsymbol{\theta}^{Per})$ 为具体函数形式的模型表达, 如威布尔分布模型、对数正态分布模型、指数分布模型和伽玛分布模型等, 可将具体函数形式代入到上述公式来获得, 此处不再赘述。

2.3.1.2 最小维修下的故障时间数据建模

在最小维修情形下, 机床每次故障后的维修只是将机床修复到该故障发生之前的状态, 即机床修复后发生故障的可能性与该故障发生之前是相同的。与“修复如新”的完好维修对应, 最小维修可描述为“修复如旧”。此时, 机床故障时间数据的建模需要将故障发生的顺序考虑进去, 需要针对故障时间序列进行建模, 其本质是要抓住在维修前后(忽略维修时间的影响)单位时间内机床发生故障的概率保持不变。本文采用 NHPP (Non-Homogeneous Poisson Process, 非齐次泊松过程) 来对最小维修情形下的故障时间序列进行建模。

某重型数控机床在单位时间内发生故障的概率为 $\omega(t)$, 该机床在时间区间 $[0, t]$ 内发生故障的次数计为 $\{N(t), t \geq 0\}$ 。当计数过程 $\{N(t), t \geq 0\}$ 为 NHPP 时, 则具有以下性质:

- (1) $N(t) = 0$ 。
- (2) 任何一组两两不交的时间区间上, 发生故障数的增量相互独立。
- (3) $\Pr(N(t + \Delta t) - N(t) = 1) = \omega(t)\Delta t + o(\Delta t)$ 。
- (4) $\Pr(N(t + \Delta t) - N(t) \geq 2) = o(\Delta t)$ 。

根据故障时间序列数据特性的不同, 可以选用不同强度函数的 NHPP 来对其进行建模。对于重型数控机床这类复杂系统, 常用的 NHPP 模型主要包括对数线性过程模型、幂律模型和双重威布尔过程模型等。由于这些模型的主要差别在于强度函数 $\omega(t)$ 的表达形式不同, 下面在不具体化强度函数的情形下, 给出最小维修下重型数控机床故障时间数据模型的一般形式。

基于强度函数为 $\omega(t)$ 的 NHPP 的第 i 台重型数控机床首次故障时间 T_{i1} 的分布

函数可表示为:

$$F^{Min}(t_{i1} | \boldsymbol{\theta}_i^{Min}) = 1 - \Pr(N(t_{i1}) = 0) = 1 - \exp\left(-\int_0^{t_{i1}} \omega_i(u | \boldsymbol{\theta}_i^{Min}) du\right) \quad (2-9)$$

式中, $\boldsymbol{\theta}_i^{Min}$ 为第 i 台机床对应的 NHPP 的参数, 也是强度函数 $\omega_i(t | \boldsymbol{\theta}_i^{Min})$ 的参数。

第 i 台重型数控机床故障时间序列中, 当观测到第 $j-1$ 个故障发生在 $t_{i,j-1}$ 时刻后, 第 j 个故障发生的时间 T_{ij} 的分布函数可表示为:

$$\begin{aligned} F^{Min}(t_{ij} | \boldsymbol{\theta}_i^{Min}, t_{i,j-1}) &= 1 - \Pr(N(t_{ij}) - N(t_{i,j-1}) = 0) \\ &= 1 - \exp\left(-\int_{t_{i,j-1}}^{t_{ij}} \omega_i(u | \boldsymbol{\theta}_i^{Min}) du\right) \end{aligned} \quad (2-10)$$

由式(2-10)可得, 当观测到第 $j-1$ 个故障发生在 $t_{i,j-1}$ 时刻后, 第 $j-1$ 个故障与第 j 个故障之间间隔时间的平均值为:

$$\text{MTBF}_{ij}^{Min} = \int_0^{\infty} \exp\left(-\int_0^t \omega_i(u + t_{i,j-1} | \boldsymbol{\theta}_i^{Min}) du\right) dt \quad (2-11)$$

对于第 i 台重型数控机床故障时间序列中, 当观测到第 $j-1$ 个故障发生在 $t_{i,j-1}$ 时刻后, 第 j 个故障发生在 t_{ij} 时刻的条件概率密度可表示为:

$$f^{Min}(t_{ij} | \boldsymbol{\theta}_i^{Min}, t_{i,j-1}) = \omega_i(t_{ij} | \boldsymbol{\theta}_i^{Min}) \exp\left(-\int_{t_{i,j-1}}^{t_{ij}} \omega_i(u | \boldsymbol{\theta}_i^{Min}) du\right) \quad (2-12)$$

与完好维修情形类似, 当需考虑机床的个体差异性时, 可将 $\boldsymbol{\theta}_i^{Min}$ 细化为 $\{\boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R\}$, 其中 $\boldsymbol{\theta}^F$ 为 n 台机床取值相同的模型参数, $\boldsymbol{\theta}_i^R$ 为所有机床共有但是取值存在个体差异性的模型参数。在此基础上, 进一步用随机变量来对 $\boldsymbol{\theta}_i^R$ 进行建模, 并赋予对应的概率密度 $f_r(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HR})$ 。此时, 式(2-9)至(2-12)描述的是考虑了个体差异性的机床各个体首次故障时间、条件故障间隔时间等对应的分布函数和概率密度表达式。对于机床总体的相应表达式, 则可通过将式(2-9)至(2-12)对随机变量 $\boldsymbol{\theta}_i^R$ 取均值来得到。

考虑个体差异性时, 故障时间序列数据 $\mathbf{t} = \{t_{ij}, i = 1, \dots, n, j = 1, \dots, m_i\}$ 所包含的机床可靠性信息, 可通过该数据集的似然函数描述如下:

$$L^{Min}(\mathbf{t} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^{HP}) = \prod_{i=1}^n f_r(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HP}) \prod_{j=1}^{m_i} f^{Min}(t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, t_{i,j-1}) \quad (2-13)$$

式中, $f^{Min}(t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, t_{i,j-1})$ 为式(2-12)描述的模型参数为 $\boldsymbol{\theta}_i^{Min} = \{\boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R\}$ 的条件概率密度函数, 且有 $t_{i0} = 0$ 。

对于最小维修下不考虑个体差异性的重型数控机床故障时间序列的模型, 可将式(2-9)至(2-12)中所有与个体差异性相关的参数统一为总体的参数, 即

$\theta_1^R = \theta_i^R = \theta_n^R = \theta^R$ 。在此情形下，故障时间序列数据 \mathbf{t} 的似然函数可表述为：

$$L^{Min}(\mathbf{t} | \theta^F, \theta^R) = \prod_{i=1}^n \prod_{j=1}^{m_i} f^{Min}(t_{ij} | \theta^F, \theta^R, t_{i,j-1}) \quad (2-14)$$

式中， $f^{Min}(t_{ij} | \theta^F, \theta^R, t_{i,j-1})$ 为式(2-12)描述的模型参数为 $\theta_i^{Min} = \{\theta^F, \theta^R\}$ 的条件概率密度函数。

对于故障强度 $\omega(t | \theta^{Min})$ 为具体函数形式的模型表达，如对数线性过程模型、幂律模型和双重威布尔过程模型等，可将具体函数形式代入到上述公式获得，此处不再赘述。

2.3.1.3 非完好维修下的故障时间数据建模

非完好维修下的故障时间数据的建模，一方面需要对故障发生的时间序列进行建模，另一方面也要对每次维修的效果进行描述；而其本质在于抓住维修前后维修作用对机床发生故障概率的改变。Pham 和 Wang^[97]，Doyen 和 Gaudoin^[98]以及 Wu 和 Zuo^[99]对现有的非完好维修模型进行了系统的综述。这些模型的主要差别在于强度函数 $\omega(t)$ 的表达形式不同，以及维修效果的作用方式不同。非完好维修对机床的作用主要通过三种形式来体现：虚拟役龄（Virtual Age）的变化、故障强度的变化以及虚拟役龄和故障强度同时变化。下面在不具体化强度函数的情形下，通过描述虚拟役龄和故障强度共同存在的变化，来给出非完好维修下机床故障时间数据模型的一般形式。

对于故障强度为 $\omega(t)$ 的重型数控机床，当观测到第 i 台机床的第 $j-1$ 个故障发生在 $t_{i,j-1}$ 时刻，在经历了非完好维修后第 j 个故障发生的故障强度可描述为以下形式：

$$\omega_{ij}(t_{ij} - t_{i,j-1} + V_{i,j-1}) = p_{i,j-1} \omega_{i,j-1}(t_{ij} - t_{i,j-1} + V_{i,j-1}) \quad (2-15)$$

式中， $\omega_{ij}(t_{ij} - t_{i,j-1} + V_{i,j-1})$ 为第 j 个故障发生时的故障强度，且有 $\omega_{i1}(t_{i1} + V_{i0})$ 等同于首次故障的故障强度； $p_{i,j-1}$ 为第 $j-1$ 个故障发生后，机床第 $j-1$ 次非完好维修所引起的故障强度降低的因子，且有 $0 < p_{i,j-1} \leq 1$ 和 $p_{i0} = 1$ ； $V_{i,j-1}$ 是第 $j-1$ 个故障发生后，对机床进行第 $j-1$ 次非完好维修后的虚拟役龄，且有 $V_{i0} = 0$ 。

虚拟役龄的引入使得机床的故障强度与实际服役时间无关，而与维修后的虚拟役龄相关。通过引入役龄回退因子 $q_{i,j-1}$ 来建立虚拟役龄与实际服役时间的关系，即可对非完好维修的效果进行建模描述。对于数控机床非完好维修建模，常用的两种役龄回退模型为 Kijima I 类和 II 类模型^{[100][101]}，可表述为：

$$V_{i,j-1} = \begin{cases} q_{i,j-1}(t_{i,j-1} - t_{i,j-2}) + V_{i,j-2}, & \text{Kijima I} \\ q_{i,j-1}(t_{i,j-1} - t_{i,j-2} + V_{i,j-2}), & \text{Kijima II} \end{cases} \quad (2-16)$$

式中， $q_{i,j-1}$ 为第 $j-1$ 次非完好维修后机床虚拟役龄的回退比例，且有 $0 \leq q_{i,j-1} \leq 1$ ；对于 Kijima I 类模型第 $j-1$ 次维修只影响第 $j-1$ 个服役周期 $\Delta t_{i,j-1} = t_{i,j-1} - t_{i,j-2}$ ，而 Kijima II 类模型则会影响机床之前所经历的所有服役周期。

综合式(2-15)和(2-16)即可获得非完好维修作用的一般化模型。当模型参数 $p_{ij} = q_{ij} = 1$ 时，非完好维修模型转化为最小维修模型；当参数 $p_{ij} = 1$ 且 $q_{ij} = 0$ 时，非完好维修模型转化为完好维修模型。用于非完好维修程度描述的因子——故障强度降低因子 $p_{i,j-1}$ 和役龄回退因子 $q_{i,j-1}$ ，其获取和确定主要有两种方法。第一种方法是对每次故障维修之后的维修效果进行专家评分，来获得每一次故障所对应的故障强度降低因子 $p_{i,j-1}$ 和役龄回退因子 $q_{i,j-1}$ 。该方法能获取每次维修所对应的因子，有利于故障数据的建模和机床的可靠性评估。然而，由于每次维修后都需要召集专家对维修效果进行评价，并且缺乏实施流程和标准的指导，在实际应用中往往受到时间、费用和主观不确定性的限制，难以切实得到应用。第二种方法是将所有故障维修后的故障强度降低因子 $p_{i,j-1}$ 和役龄回退因子 $q_{i,j-1}$ 统一为相等的值，即假设 $p_{i,1} = p_{i,j} = p_i$ ， $q_{i,1} = q_{i,j} = q_i$ 。该方法能够将模型进行较大的简化并降低求解的难度，然而将这些因子统一对等的假设却难以与实际情况相符合，往往会带来建模和评估的偏差。两种方法的选择应用，应根据实际情况所具备的条件和资源来确定。

在此基础上，考虑第 i 台重型数控机床，当观测到第 $j-1$ 个故障发生在 $t_{i,j-1}$ 时刻后，第 j 个故障发生的时间 T_{ij} 的分布函数可表示为：

$$\begin{aligned} F^{Imp}(t_{ij} | \boldsymbol{\theta}_i^{Imp}, t_{i,j-1}) &= 1 - \Pr(N(t_{ij} - t_{i,j-1} + V_{i,j-1}) - N(V_{i,j-1}) = 0) \\ &= 1 - \exp\left(-\int_{t_{i,j-1}}^{t_{ij}} \omega_{ij}(u - t_{i,j-1} + V_{i,j-1} | \boldsymbol{\theta}_i^{Imp}) du\right) \end{aligned} \quad (2-17)$$

式中， $\boldsymbol{\theta}_i^{Imp}$ 为第 i 台机床对应的非完好维修模型的参数。

由式(2-17)可得，当观测到第 $j-1$ 个故障发生在 $t_{i,j-1}$ 时刻后，第 $j-1$ 个故障与第 j 个故障之间间隔时间的平均值为：

$$\text{MTBF}_{ij}^{Imp} = \int_0^{\infty} \exp\left(-\int_{t_{i,j-1}}^t \omega_{ij}(u - t_{i,j-1} + V_{i,j-1} | \boldsymbol{\theta}_i^{Imp}) du\right) dt \quad (2-18)$$

同理，当观测到第 $j-1$ 个故障发生在 $t_{i,j-1}$ 时刻且对应的虚拟役龄为 $V_{i,j-1}$ 后，第 j 个故障发生在 t_{ij} 时刻的条件概率密度可表示为：

$$f^{Imp}(t_{ij} | \boldsymbol{\theta}_i^{Imp}, t_{i,j-1}) = \omega_{ij}(t_{ij} - t_{i,j-1} + V_{i,j-1} | \boldsymbol{\theta}_i^{Imp}) \times \exp\left(-\int_{t_{i,j-1}}^{t_{ij}} \omega_{ij}(u - t_{i,j-1} + V_{i,j-1} | \boldsymbol{\theta}_i^{Imp}) du\right) \quad (2-19)$$

与最小维修情形类似，当需考虑机床的个体差异性时，可将 $\boldsymbol{\theta}_i^{Imp}$ 细化为 $\{\boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R\}$ ，并将随机参数 $\boldsymbol{\theta}_i^R$ 用概率密度为 $f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HP})$ 的随机变量来进行建模。此时，式(2-17)和(2-18)描述的是考虑了个体差异性的机床各个体条件故障间隔时间和条件 MTBF 的表达式。对于机床总体的相应表达式，则可通过将式(2-17)和(2-18)对随机变量 $\boldsymbol{\theta}_i^R$ 取均值来得到。

考虑个体差异性时，故障时间序列数据 $\mathbf{t} = \{t_{ij}, i = 1, \dots, n, j = 1, \dots, m_i\}$ 所包含的机床可靠性信息，可通过该数据集的似然函数描述如下：

$$L^{Imp}(\mathbf{t} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^{HP}) = \prod_{i=1}^n f_R(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^{HP}) \prod_{j=1}^{m_i} f^{Imp}(t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, t_{i,j-1}) \quad (2-20)$$

式中， $f^{Imp}(t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, t_{i,j-1})$ 为式(2-19)描述的参数为 $\boldsymbol{\theta}_i^{Imp} = \{\boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R\}$ 的条件概率密度函数，且有 $t_{i0} = 0$ 。

对于非完好维修下不考虑个体差异性的机床故障时间序列的模型，可将式(2-17)至(2-19)中的随机效应参数用总体参数取代，即 $\boldsymbol{\theta}_1^R = \boldsymbol{\theta}_i^R = \boldsymbol{\theta}_n^R = \boldsymbol{\theta}^R$ 。在此情形下，故障时间序列数据 \mathbf{t} 的似然函数可表述为：

$$L(\mathbf{t} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^R) = \prod_{i=1}^n \prod_{j=1}^{m_i} f^{Imp}(t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^R, t_{i,j-1}) \quad (2-21)$$

式中， $f^{Imp}(t_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R, t_{i,j-1})$ 为式(2-19)描述的模型参数为 $\boldsymbol{\theta}_i^{Imp} = \{\boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R\}$ 的条件概率密度函数。

对于故障强度 $\omega(t | \boldsymbol{\theta}_i^{Imp})$ 为具体函数形式的建模表达，可将具体函数形式代入上述公式获得，此处不再赘述。

2.3.2 考虑故障关联程度的故障时间数据建模

在对故障时间数据进行建模时，对于每一个时间点的数据需要明确判断该时间点所对应的故障是否为关联故障。如果是关联故障则需要计入数据建模中，如果不是则需要予以排除。对于重型数控机床这类大型、复杂系统，故障模式的多样以及影响因素的繁多，某一故障是否为关联故障往往难以进行准确的判定。例如某重型数控机床出现“主轴润滑压力低而停机”的故障，经检测发现是由于“分油器压力检测口堵塞”的原因所造成。进一步分析造成检测口堵塞的原因包括：定期预防性维修不到位没有及时清洗疏通检测口，主轴零部件磨损严重产生大量

的磨损颗粒造成检测口堵塞。当该故障是由于维修的原因所造成时，则为非关联故障；而当该故障是由于机床零部件的磨损或损坏造成时，则为关联故障。

信息的缺失和机理的不明确，往往导致重型数控机床故障数据分析中存在关联程度难以确定的问题。这一问题从广义的角度为基于部分相关信息（Partially Relevant Information）的可靠性建模与评估问题^[102-104]。Droguett 和 Mosleh^[102]在研究模型不确定问题时，提出了部分相关信息的建模和处理方法。针对重型数控机床的故障时间数据建模，部分相关信息是指那些与机床可靠性特征量之间存在着关联关系，但不是完全关联的故障时间信息。如果用取值在 $[0,1]$ 区间上的故障关联因子 α ，来描述某故障时间数据与机床可靠性之间的关联程度： $\alpha = 0$ 代表该故障时间数据与机床可靠性完全不相关，即该故障时间数据对应的故障为非关联故障； $\alpha = 1$ 则代表该故障时间数据与机床可靠性完全相关，即对应的故障为关联故障； $0 < \alpha < 1$ 则代表该故障时间数据与机床可靠性部分相关，即难以准确区分该故障是否为关联故障。对于图 2-1 所示的重型数控机床的故障时间数据，可通过机床主机厂和用户厂的工程人员对每次故障的故障模式、故障原因和维修处理方法进行分析，采用专家评定的方法给出每次故障与机床可靠性关联程度的故障关联因子 α_{ij} 。此时，机床的故障时间数据可进一步描述为图 2-2 所示的形式。

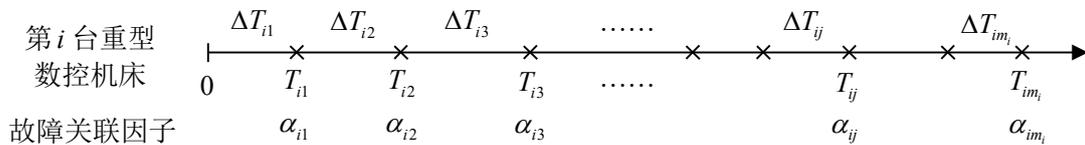


图 2-2 考虑故障关联程度的故障时间序列数据

当考虑维修程度时，故障时间数据的模型可由式(2-7)、(2-13)或(2-20)来进行描述。当同时考虑维修程度和故障关联程度时，则需要将故障关联因子引入到已经建立的考虑维修程度的故障时间数据模型中。故障时间数据所包含的机床可靠性信息主要是通过似然函数来表达的，同时似然函数是机床可靠性模型参数估计的根本所在。当某一故障的关联程度较高时，该故障的故障时间数据对似然函数的贡献作用应该较大；反之，如果关联程度较弱，则相应的贡献作用较弱。因此，可以通过故障关联因子 α_{ij} 来对每一故障对应的故障时间数据 t_{ij} 在似然函数中的作用进行调整，从而实现故障关联程度在模型中的引入和体现。

令 $l(t_{ij} | \theta)$ 为第 i 台重型数控机床第 j 个故障数据 t_{ij} 在似然函数 $L(\mathbf{t} | \theta)$ 中的贡献量。通过对比分析式(2-7)、(2-13)和(2-20)所描述的故障时间数据的似然函数，可以得出 $L(\mathbf{t} | \theta)$ 往往由所有故障时间数据的 $l(t_{ij} | \theta)$ 连乘所得。因此，将故障关联因子 α_{ij} 作为 $l(t_{ij} | \theta)$ 的指数项，引入到故障时间数据 t_{ij} 所对应的似然函数中，可以

得到：

$$L(\mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta}) = \prod_{i=1}^n \prod_{j=1}^{m_i} [l(t_{ij} | \boldsymbol{\theta})]^{\alpha_{ij}} \quad (2-22)$$

进一步，取似然函数的自然对数可得：

$$\log(L(\mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta})) = \sum_{i=1}^n \sum_{j=1}^{m_i} \alpha_{ij} \log(l(t_{ij} | \boldsymbol{\theta})) \quad (2-23)$$

由于 α_{ij} 是在 $[0,1]$ 区间上取值的故障关联因子， α_{ij} 的取值越大表明故障时间数据与机床的可靠性关联度越大，这种关联关系可通过 α_{ij} 在式(2-22)和(2-23)中的“权重作用”所表达出来。这种“权重作用”的本质在于 α_{ij} 对似然函数分散性的调整，当 α_{ij} 越小时，在其作用下的似然函数在参数 $\boldsymbol{\theta}$ 的取值区间越分散，其作用示意图如图 2-3 所示。

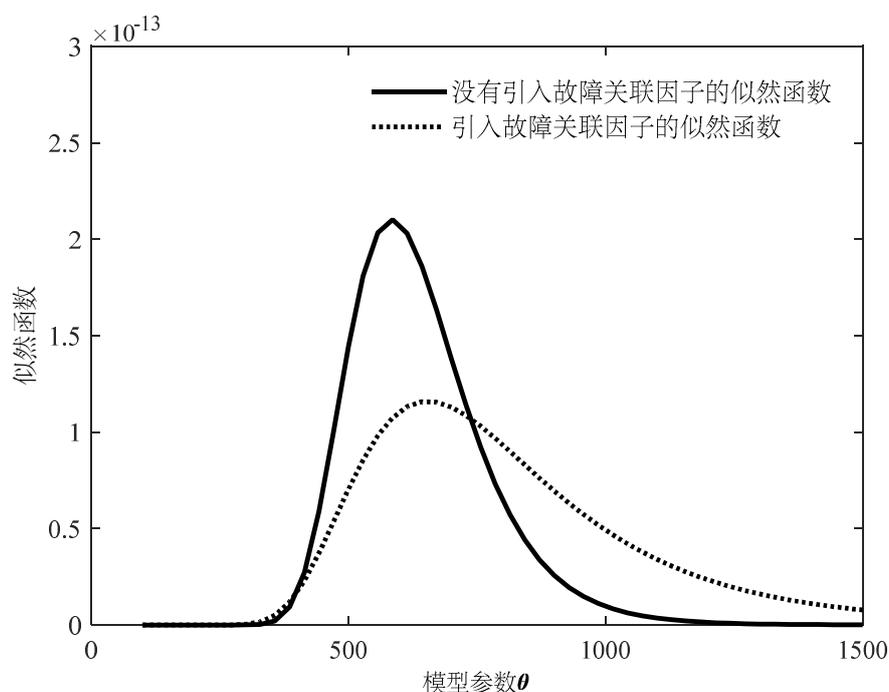


图 2-3 故障关联因子对似然函数作用的示意图

故障关联因子对于某一故障时间点的作用可以更为直观的描述为：当 $\alpha_{ij} = 0$ 时，其所对应的故障为非关联故障，该数据在似然函数中得到排除；而当 $\alpha_{ij} = 1$ 时，其所对应的故障为关联故障，该数据在似然函数中得到完整计入；当 $0 < \alpha_{ij} < 1$ 且取值越大时， $l(t_{ij} | \boldsymbol{\theta})$ 在整个似然函数中所体现出的作用量越大。

根据这样的思路，结合考虑维修程度的故障时间数据的模型，可以进一步建立同时考虑维修程度和故障关联程度的故障时间数据的模型。

完好维修情形下考虑故障关联程度的影响，重型数控机床的故障时间数据 $\{\Delta t, \alpha\} = \{\Delta t_{ij}, \alpha_{ij}, i = 1, \dots, n, j = 1, \dots, m_i\}$ 所包含的机床可靠性信息可描述如下：

$$L^{Per}(\Delta t, \alpha | \theta^F, \theta^R, \theta^{HP}) = \prod_{i=1}^n f_R(\theta_i^R | \theta^{HP}) \prod_{j=1}^{m_i} f^{Per}(\Delta t_{ij} | \theta^F, \theta_i^R)^{\alpha_{ij}} \quad (2-24)$$

式中， $f^{Per}(\Delta t_{ij} | \theta^F, \theta_i^R)$ 为式(2-2)描述的参数为 $\theta_i^{Per} = \{\theta^F, \theta_i^R\}$ 的概率密度函数。

最小维修情形下考虑故障关联程度的影响，重型数控机床机床的故障时间数据 $\{t, \alpha\} = \{t_{ij}, \alpha_{ij}, i = 1, \dots, n, j = 1, \dots, m_i\}$ 所包含的机床可靠性信息可描述如下：

$$L^{Min}(t, \alpha | \theta^F, \theta^R, \theta^{HP}) = \prod_{i=1}^n f_R(\theta_i^R | \theta^{HP}) \prod_{j=1}^{m_i} f^{Min}(t_{ij} | \theta^F, \theta_i^R, t_{i,j-1})^{\alpha_{ij}} \quad (2-25)$$

式中， $f^{Min}(t_{ij} | \theta^F, \theta_i^R, t_{i,j-1})$ 为式(2-12)描述的参数为 $\theta_i^{Min} = \{\theta^F, \theta_i^R\}$ 的条件概率密度函数。

非完好维修情形下考虑故障关联程度的影响，故障时间数据 $\{t, \alpha\}$ 所包含的机床可靠性信息描述如下：

$$L^{Imp}(t, \alpha | \theta^F, \theta^R, \theta^{HP}) = \prod_{i=1}^n f_R(\theta_i^R | \theta^{HP}) \prod_{j=1}^{m_i} f^{Imp}(t_{ij} | \theta^F, \theta_i^R, t_{i,j-1})^{\alpha_{ij}} \quad (2-26)$$

式中， $f^{Imp}(t_{ij} | \theta^F, \theta_i^R, t_{i,j-1})$ 如式(2-19)所示且 $\theta_i^{Imp} = \{\theta^F, \theta_i^R\}$ 和 $t_{i0} = 0$ 。

2.4 基于贝叶斯模型综合的重型数控机床可靠性评估

在给出故障时间数据建模方法的基础上，如何将故障数据中包含的可靠性信息转换为模型参数的信息并获得模型参数的估计；在此基础上，如何根据所建立的模型与可靠性特征量之间的关系进一步获得可靠性特征量的估计；这两个估计问题是可靠性评估的关键所在。对于重型数控机床基于故障时间数据的可靠性评估，由于存在数据量较少、考虑因素较多和模型结构复杂等特性，一方面需要在数据较少的情形下选择合适的模型对其进行建模，另一方面需要综合考虑模型的不确定性与参数的不确定性以准确得到可靠性特征量的评估结果。

对于模型选择的问题，常用的方法是采用概率图检验^[105]、趋势检验^[106]以及 AIC (Akaike Information Criterion) 和 BIC (Bayesian Information Criterion) ^[107] 等信息准则的模型选择方法。这些方法往往是从多个适用的模型中选择最优的模型，来开展数据建模和可靠性评估工作。当数据量较少而需要考虑的建模因素较多时，往往难以选择“最优”的模型却可能同时存在多个“次优”的模型，此时单独选择一个模型会使得数据建模较为局限、评估结果偏差较大。同时，考虑到可靠性模型和可靠性评估结果会进一步应用到可靠性设计、可靠性验证以及机床运行维

护和健康管理决策中，这使得可靠性建模和评估中需要考虑参数不确定性和模型不确定性等问题。本文将贝叶斯模型综合（Bayesian Model Averaging, BMA）方法^[109-111]引入到重型数控机床故障时间数据的建模中，通过将适用的模型作为可靠性评估信息的一种，在贝叶斯框架下用随机变量对其信息进行表征，并与相应模型参数的信息进行融合，以实现基于多模型融合的可靠性评估。

2.4.1 贝叶斯模型综合方法的基本框架

贝叶斯模型综合方法的核心在于将模型集中所有的模型以及各模型对应的参数都当做随机变量。通过利用观测到的样本信息，将这些随机变量的初始认知进行信息的更新和融合，以得到模型和模型参数的更新认知，最后综合所有模型更新认知下的分析结果来得出最终分析评估的结果。在贝叶斯模型综合方法中，样本信息、模型和参数的初始认知和更新认知分别被描述为似然函数、先验分布和后验分布。贝叶斯模型综合方法的基本框架如图 2-4 所示。

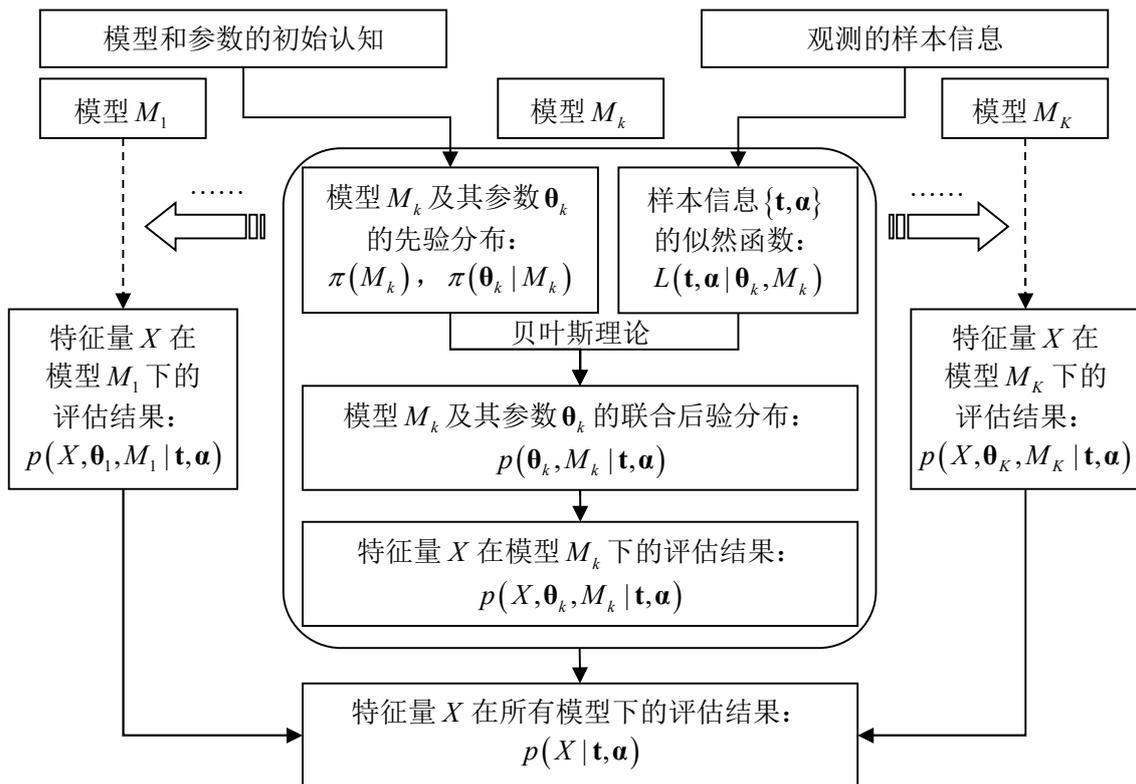


图 2-4 贝叶斯模型综合方法的基本框架

对于某一观测到的样本信息 $\{\mathbf{t}, \boldsymbol{\alpha}\}$ ，当存在 K 个适用的模型时，BMA 方法综合了所有模型的贝叶斯评估结果，来得到特征量最终的评估结果。对于某一模型 M_k ($k=1, \dots, K$)，应用贝叶斯方法将观测的样本信息 $\{\mathbf{t}, \boldsymbol{\alpha}\}$ 与该模型及其参数的

先验分布进行融合更新，得到该模型下模型和参数的联合后验分布，然后通过模型参数与可靠性特征量的关系，即可得到该模型下可靠性特征量的评估结果。在得到所有 K 个模型下评估结果的基础上，根据各模型的后验分布来综合获得特征量在所有模型下的评估结果。

基于图 2-4 所示的基本框架，BMA 方法的实施主要包括以下关键步骤：

- (1) 根据样本信息的特性，结合常用的模型选择方法确定适用的模型集。
- (2) 根据模型集中各模型的特性，考虑已有的先验信息形成模型及其对应参数的初始认知，并在此基础上得到先验分布。
- (3) 根据贝叶斯方法，考虑样本信息、多模型结构和先验信息的形式和结构特征，构建多模型的数学表达。
- (4) 根据后验分布的表达，考虑可靠性特征量和模型参数的关系特性，应用贝叶斯后验分布的求解方法获取特征量的估计。

2.4.2 重型数控机床基于贝叶斯模型综合的可靠性评估实现

在以上故障时间数据特性的分析、一般化模型的建立以及评估方法基本框架构建的基础上，下面针对图 2-2 所示的故障时间数据，建立重型数控机床考虑维修程度和故障关联程度的可靠性评估实现。

- (1) 故障时间数据考虑维修程度和故障关联程度的模型集

适用于重型数控机床故障时间数据的模型已在 2.3 节中进行了系统的描述。对于某一故障时间数据模型集的确定：首先需结合 2.2 节中关于故障时间数据特性和类型的分析，从 2.3 节给出的模型中选择若干模型构成初始模型集；然后应用模型选择方法，对初始模型集中的模型进行初步筛选，来确定用于贝叶斯模型综合分析的模型集。

- (2) 故障时间数据模型参数的贝叶斯模型综合估计

根据图 2-4 所示的基本框架，当给定 K 个模型和各模型下对应参数的先验分布，结合式(2-24)至(2-26)所示的不同维修程度和关联程度下的似然函数，可得基于贝叶斯模型综合的模型参数估计如下：

$$p(\boldsymbol{\theta}_k, M_k | \mathbf{t}, \boldsymbol{\alpha}) = \frac{L(\mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta}_k, M_k) \pi(\boldsymbol{\theta}_k | M_k) \pi(M_k)}{\sum_{k=1}^K \int_{\boldsymbol{\theta}_k} L(\mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta}_k, M_k) \pi(\boldsymbol{\theta}_k | M_k) \pi(M_k) d\boldsymbol{\theta}_k} \quad (2-27)$$

式中， $\pi(M_k)$ 为模型 M_k 作为故障时间数据模型的先验概率， $\pi(\boldsymbol{\theta}_k | M_k)$ 为模型 M_k 的模型参数 $\boldsymbol{\theta}_k$ 的先验分布， $L(\mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta}_k, M_k)$ 为故障数据 $\{\mathbf{t}, \boldsymbol{\alpha}\}$ 在模型 M_k 下的似然函数， $p(\boldsymbol{\theta}_k, M_k | \mathbf{t})$ 是模型 M_k 及其模型参数的后验分布。

1) 模型 M_k 先验分布的获取及表征

模型 M_k 的初始认知信息（先验信息）主要来源于该模型在同形式故障时间数据以及同类型重型数控机床中应用的专家经验和历史经验^[102]。这一类先验信息的获取主要考虑两个关键的方面：模型的抽象性和模型的适用性。模型的抽象性主要是考虑模型对故障时间数据的概括能力，例如是否考虑了维修程度和关联程度的影响。模型的适用性主要是考虑模型在实际工程中的应用能力，例如该模型是否在实际工程中得到广泛的应用和验证，是否存在理解运用的误区或者计算实现的难度等。Droguett 和 Mosleh^[104]对与模型相关信息的获取方法进行了讨论和示例描述。关于专家经验信息的获取与量化，则可进一步参考 O'Hagan 等^[113]关于专家概率获取的理论和方法。基于专家经验和历史经验信息的先验分布是 M_k 初始认知数学表达的一种，属于有信息先验分布（Informative Prior Distribution）。此外，当先验信息较少或者难以获取时，可以采用无信息先验分布（Non-informative Prior Distribution）的形式来描述对模型 M_k 的初始认知。两种先验分布可统一用类别分布（Categorical Distribution）来进行描述，其表达式如下：

$$\pi(M_k) = \begin{cases} p_{M_k}, & \text{如果 } M_k \text{ 为真} \\ 0, & \text{其他} \end{cases}, 0 \leq p_{M_k} \leq 1, \sum_{k=1}^K p_{M_k} = 1 \quad (2-28)$$

式中， p_{M_k} 为模型 M_k 作为故障时间数据模型的概率；对于有信息先验分布的情形， p_{M_k} 为专家经验和历史经验信息量化所得的概率；对于无信息先验分布的情形，所有 K 个模型的取值相等，且都为 $p_{M_k} = 1/K$ 。

2) 模型参数 θ_k 先验分布的获取及表征

与模型 M_k 的先验分布相对应，模型参数 θ_k 先验分布主要包括：基于历史经验和专家经验信息的有信息先验分布，以及当这些先验信息难以获取时的无信息先验分布。基于历史经验和专家经验信息先验分布的获取主要考虑以下两个关键的方面。第一个方面，从模型所描述的特征量的均值、方差和分位值的角度，来获取并量化历史经验和专家经验信息，并通过模型参数与可靠性特征量之间的关系，将量化的信息转换为模型参数的先验分布^[115-116]。第二个方面，从同型号机床的故障时间数据的分析结果中，提取模型参数的估计结果，并通过主观对比同型号机床在特征量上的差别，将提取的模型参数估计结果转换为当前模型参数的先验分布^[116]。对于取值区间在 $[0, +\infty]$ 上的模型参数，常用的有信息先验分布主要包括：对数正态分布、伽玛分布、威布尔分布、截尾正态分布、卡方分布（Chi-square Distribution）、贝塔分布（Beta Distribution）和狄利克雷分布（Dirichlet Distribution）等。对于取值区间在 $[-\infty, +\infty]$ 区间上的模型参数，常用的有信息先验分布主要是正

态分布和多维正态分布。对于无信息先验分布，采用得较多的先验分布主要是均匀分布和共轭先验分布。

3) 故障时间数据似然函数的数学表征

根据重型数控机床故障时间数据的特性分析，本章在 2.3 节中建立了故障时间数据模型的一般化形式，即没有明确给出故障率函数 $\lambda(t)$ 和故障强度函数 $\omega(t)$ 具体表达式下的模型。下面通过给出 $\lambda(t)$ 和 $\omega(t)$ 的常见形式，并将这些具体的表达式代入到式(2-24)至(2-26)所示的似然函数中，即可获得故障时间考虑维修程度和故障关联程度的模型集。值得说明的是：故障率函数 $\lambda(t)\Delta t$ 是指机床在工作 t 时间后在单位时间 Δt 内发生故障的条件概率，是描述机床发生故障的相对率值；而故障强度函数 $\omega(t)\Delta t$ 描述的是机床在单位时间 Δt 内发生故障的概率，是描述机床发生故障的绝对率值。

常见的完好维修下的故障率函数 $\lambda(t)$ ，主要包括以下模型对应的故障率函数。

指数分布模型对应的故障率函数：

$$\lambda_i(t_{ij} | \lambda_i^{Exp}) = \lambda_i^{Exp} \quad (2-29)$$

式中， λ_i^{Exp} 为指数分布的模型参数，且有 $\lambda_i^{Exp} > 0$ 。

威布尔分布模型对应的故障率函数：

$$\lambda_i(t_{ij} | \beta_i, \eta_i) = \frac{\beta_i}{\eta_i} \left(\frac{t_{ij}}{\eta_i} \right)^{\beta_i - 1} \quad (2-30)$$

式中， β_i 和 η_i 分别为威布尔分布的形状参数和尺度参数，且有 $\beta_i > 0$ 和 $\eta_i > 0$ 。

对数正态分布模型对应的故障率函数：

$$\lambda_i(t_{ij} | \mu_i, \sigma_i) = \frac{\exp\left(-\frac{1}{2}\left(\frac{\ln(t_{ij}) - \mu_i}{\sigma_i}\right)^2\right)}{t_{ij} \int_{t_{ij}}^{\infty} \exp\left(-\frac{1}{2}\left(\frac{\ln(u) - \mu_i}{\sigma_i}\right)^2\right) du} \quad (2-31)$$

式中， μ_i 和 σ_i 分别为服从正态分布的 $\log(t_{ij})$ 的均值和标准差，且有 $\sigma_i > 0$ 。

伽玛分布模型对应的故障率函数：

$$\lambda_i(t_{ij} | \tau_i, \nu_i) = \frac{t_{ij}^{\tau_i - 1} \exp(-t_{ij}/\nu_i)}{\nu_i^{\tau_i} \int_0^{t_{ij}/\nu_i} u^{\tau_i - 1} e^{-u} du} \quad (2-32)$$

式中， τ_i 和 ν_i 分别为伽玛分布的形状参数和尺度参数，且有 $\tau_i > 0$ 和 $\nu_i > 0$ 。

双重威布尔分布模型^[29]对应的故障率函数：

$$\lambda_i(t_{ij} | a_i, b_i, c_i, d_i) = a_i b_i (a_i t_{ij})^{b_i-1} + c_i d_i (c_i t_{ij})^{d_i-1} \quad (2-33)$$

式中, $a_i \geq 0$ 和 $b_i > 1$, 且 $(a_i t_{ij})^{b_i}$ 本质上为一个故障率单调递增的威布尔分布对应的故障率函数; $c_i \geq 0$ 和 $0 < d_i < 1$, 且 $(c_i t_{ij})^{d_i}$ 本质上为一个故障率单调递减的威布尔分布对应的故障率函数。该双重威布尔分布模型是若干故障率曲线为“浴盆曲线”的模型之一, 对于其他的浴盆曲线模型可参见 Almalki 和 Nadarajah^[27]以及 Pham 和 Lai^[30]的综述。

常见的故障强度函数 $\omega(t)$, 主要有以下随机过程所对应的故障强度函数^[111]:
齐次泊松过程模型对应的故障强度函数:

$$\omega_i(t_{ij} | \lambda_i^H) = \lambda_i^H \quad (2-34)$$

式中, λ_i^H 为齐次泊松过程的模型参数, 且有 $\lambda_i^H > 0$ 。

威布尔过程模型对应的故障强度函数:

$$\omega_i(t_{ij} | \beta_i^{NH}, \eta_i^{NH}) = \frac{\beta_i^{NH}}{\eta_i^{NH}} \left(\frac{t_{ij}}{\eta_i^{NH}} \right)^{\beta_i^{NH}-1} \quad (2-35)$$

式中, β_i^{NH} 为形状参数, η_i^{NH} 为尺度参数, 且有 $\beta_i^{NH} > 0$ 和 $\eta_i^{NH} > 0$ 。

双威布尔过程模型^[112]对应的故障强度函数:

$$\omega_i(t_{ij} | a_i^{NH}, b_i^{NH}, c_i^{NH}, d_i^{NH}) = a_i^{NH} b_i^{NH} (a_i^{NH} t_{ij})^{b_i^{NH}-1} + c_i^{NH} d_i^{NH} (c_i^{NH} t_{ij})^{d_i^{NH}-1} \quad (2-36)$$

式中, $a_i^{NH} \geq 0$ 和 $b_i^{NH} > 1$, 且 $(a_i^{NH} t_{ij})^{b_i^{NH}}$ 本质上为一个故障强度单调递增的威布尔过程模型的故障率函数; $c_i^{NH} \geq 0$ 和 $0 < d_i^{NH} < 1$, 且 $(c_i^{NH} t_{ij})^{d_i^{NH}}$ 本质上为一个故障强度单调递减的威布尔过程模型的故障率函数。

下面以威布尔分布所对应的故障率函数和威布尔过程所对应的故障强度函数为例, 给出图 2-2 所示的故障时间数据在不同维修程度下的似然函数表达式。

完好维修情形下考虑故障关联程度的影响, 当选用式(2-30)所示的故障率函数所对应的威布尔分布, 来对故障时间数据 $\{\Delta \mathbf{t}, \boldsymbol{\alpha}\} = \{\Delta t_{ij}, \alpha_{ij}, i=1, \dots, n, j=1, \dots, m_i\}$ 进行建模时, 其似然函数可描述如下:

$$\begin{aligned} L^{Per}(\Delta \mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^R, \boldsymbol{\theta}^{HR}) &= \prod_{i=1}^n \frac{1}{\eta_i \sigma_\eta \sqrt{2\pi}} \exp\left(-\frac{(\log(\eta_i) - \mu_\eta)^2}{2\sigma_\eta^2}\right) \\ &\times \prod_{j=1}^{m_i} \left(\frac{\beta}{\eta_i} \left(\frac{\Delta t_{ij}}{\eta_i} \right)^{\beta-1} \exp\left(-\left(\frac{\Delta t_{ij}}{\eta_i} \right)^\beta\right) \right)^{\alpha_{ij}} \end{aligned} \quad (2-37)$$

式中, $\boldsymbol{\theta}^F = \{\beta\}$, $\boldsymbol{\theta}^R = \{\eta_i\}$ 和 $\boldsymbol{\theta}^{HR} = \{\mu_\eta, \sigma_\eta\}$ 分别对应于模型中不受产品差异性影响

的参数（固定参数）、随机效应参数（随机参数）和超参数，随机效应参数的概率分布为对数正态分布 $\eta_i \sim \text{Lognormal}(\mu_\eta, \delta_\eta)$ 。

最小维修情形下考虑故障关联程度的影响，当选用式(2-35)所示的故障强度函数所对应的威布尔过程，来对故障时间数据 $\{\mathbf{t}, \boldsymbol{\alpha}\} = \{t_{ij}, \alpha_{ij}, i=1, \dots, n, j=1, \dots, m_i\}$ 进行建模时，其似然函数可描述如下：

$$L^{\text{Min}}(\mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^R, \boldsymbol{\theta}^{\text{HR}}) = \prod_{i=1}^n \frac{\eta_i^{a_\eta - 1} \exp(-\eta_i/b_\eta)}{\Gamma(a_\eta) b_\eta^{a_\eta}} \times \prod_{j=1}^{m_i} \left(\frac{\beta}{\eta_i} \left(\frac{t_{ij}}{\eta_i} \right)^{\beta-1} \exp \left(- \left(\frac{t_{ij}}{\eta_i} \right)^\beta + \left(\frac{t_{i,j-1}}{\eta_i} \right)^\beta \right) \right)^{\alpha_{ij}} \quad (2-38)$$

式中， $\boldsymbol{\theta}^F = \{\beta\}$ ， $\boldsymbol{\theta}^R = \{\eta_i\}$ 和 $\boldsymbol{\theta}^{\text{HR}} = \{\mu_\eta, \delta_\eta\}$ ，随机效应参数的概率分布为伽玛分布 $\eta_i \sim \text{Gamma}(a_\eta, b_\eta)$ ， $\Gamma(a_\eta)$ 为伽玛函数且有 $\Gamma(a_\eta) = \int_0^\infty u^{a_\eta-1} e^{-u} du$ 。

非完好维修情形下考虑故障关联程度的影响，当选用式(2-35)所示的故障强度函数所对应的威布尔过程来对故障时间数据 $\{\mathbf{t}, \boldsymbol{\alpha}\}$ 建模时，其似然函数可描述如下：

$$L^{\text{Imp}}(\Delta \mathbf{t}, \boldsymbol{\alpha} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^R, \boldsymbol{\theta}^{\text{HR}}) = \prod_{i=1}^n \frac{\eta_i^{a_\eta - 1} \exp(-\eta_i/b_\eta)}{\Gamma(a_\eta) b_\eta^{a_\eta}} \times \prod_{j=1}^{m_i} \left(\prod_{l=0}^{j-1} \frac{\beta}{\eta_i} \left(\frac{\Delta t_{ij} + V_{i,j-1}}{\eta_i} \right)^{\beta-1} \exp \left(- \prod_{l=0}^{j-1} \left(\left(\frac{\Delta t_{ij} + V_{i,j-1}}{\eta_i} \right)^\beta - \left(\frac{V_{i,j-1}}{\eta_i} \right)^\beta \right) \right) \right)^{\alpha_{ij}} \quad (2-39)$$

$$\prod_{l=0}^{j-1} = \begin{cases} \sum_{l=0}^{j-1} q_{il} \Delta t_{il}, \text{ Kijima I} \\ \sum_{l=0}^{j-1} \left(\prod_{s=0}^{j-1} q_{is} \right) \Delta t_{il}, \text{ Kijima II} \end{cases} \quad (2-40)$$

式中， $\boldsymbol{\theta}^F = \{\beta\}$ ， $\boldsymbol{\theta}^R = \{\eta_i\}$ 和 $\boldsymbol{\theta}^{\text{HR}} = \{\mu_\eta, \delta_\eta\}$ ，随机效应参数的概率分布为伽玛分布 $\eta_i \sim \text{Gamma}(a_\eta, b_\eta)$ 。

考虑到不完全维修模型中故障强度降低因子 $p_{i,j-1}$ 和役龄回退因子 $q_{i,j-1}$ 获取方式的不同，式(2-39)和(2-40)所示的似然函数可以进一步表示为以下方式。

当每次故障的故障强度降低因子 $p_{i,j-1}$ 和役龄回退因子 $q_{i,j-1}$ 都随着故障时间数据的获取通过专家评定的方法得到且记为 $\{\mathbf{p}, \mathbf{q}\} = \{(p_{ij}, q_{ij}), i=1, \dots, n, j=1, \dots, m_i\}$ 时，故障时间数据 $\{\mathbf{t}, \boldsymbol{\alpha}, \mathbf{p}, \mathbf{q}\}$ 的似然函数可用式(2-39)和(2-40)来描述。

当假设所有的故障强度降低因子 $p_{i,j-1}$ 和役龄回退因子 $q_{i,j-1}$ 都相等且记为 $p_{i,j} = p_i$ 和 $q_{i,j} = q_i$ 时，故障时间数据 $\{\mathbf{t}, \boldsymbol{\alpha}\}$ 的似然函数可描述为：

$$L^{Imp}(\Delta t, \mathbf{a} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^R, \boldsymbol{\theta}^{HR}) = \prod_{i=1}^n \frac{\eta_i^{a_\eta - 1} \exp(-\eta_i/b_\eta)}{\Gamma(a_\eta) b_\eta^{a_\eta}} \times \prod_{j=1}^{m_i} \left(p_i^{j-1} \frac{\beta}{\eta_i} \left(\frac{\Delta t_{ij} + V_{i,j-1}}{\eta_i} \right)^{\beta-1} \exp \left(-p_i^{j-1} \left(\left(\frac{\Delta t_{ij} + V_{i,j-1}}{\eta_i} \right)^\beta - \left(\frac{V_{i,j-1}}{\eta_i} \right)^\beta \right) \right) \right)^{\alpha_{ij}} \quad (2-41)$$

$$V_{i,j-1} = \begin{cases} q_i t_{i,j-1}, \text{Kijima I} \\ \sum_{l=0}^{j-1} q_i^{j-l} \Delta t_{il}, \text{Kijima II} \end{cases} \quad (2-42)$$

式中, $\boldsymbol{\theta}^F = \{\beta, p_i, q_i\}$, $\boldsymbol{\theta}^R = \{\eta_i\}$ 和 $\boldsymbol{\theta}^{HR} = \{\mu_\eta, \sigma_\eta\}$, 随机效应参数的概率分布为伽玛分布 $\eta_i \sim \text{Gamma}(a_\eta, b_\eta)$ 。

4) 模型和模型参数后验分布的表征

将上文给出的模型的先验分布、模型参数的先验分布以及故障时间数据的似然函数代入式(2-27), 即可得到模型及模型参数后验分布的表达式。下面以完好维修情形下, 故障时间数据 $\{\Delta t, \mathbf{a}\}$ 在 M_k 为威布尔分布模型时为例, 给出模型和模型参数后验分布的表达式:

$$p(\boldsymbol{\theta}_k, M_k | \Delta t, \mathbf{a}) \propto p_{M_k} \times \frac{\beta^{a_\beta - 1} \exp(-\beta/b_\beta)}{\Gamma(a_\beta) \beta^{a_\beta}} \times \frac{1}{\sigma_{\mu_\eta} \sqrt{2\pi}} \exp \left(-\frac{(\mu_\eta - \mu_{\mu_\eta})^2}{2\sigma_{\mu_\eta}^2} \right) \times \frac{\sigma_\eta^{a_{\sigma_\eta} - 1} \exp(-\sigma_\eta/b_{\sigma_\eta})}{\Gamma(a_{\sigma_\eta}) \sigma_\eta^{a_{\sigma_\eta}}} \times \prod_{i=1}^n \left(\frac{1}{\eta_i \sigma_\eta \sqrt{2\pi}} \exp \left(-\frac{(\log(\eta_i) - \mu_\eta)^2}{2\sigma_\eta^2} \right) \times \prod_{j=1}^{m_i} \left(\frac{\beta}{\eta_i} \left(\frac{\Delta t_{ij}}{\eta_i} \right)^{\beta-1} \exp \left(-\left(\frac{\Delta t_{ij}}{\eta_i} \right)^\beta \right) \right)^{\alpha_{ij}} \right) \quad (2-43)$$

式中, $\boldsymbol{\theta}_k = \{\beta, \boldsymbol{\eta}, \mu_\eta, \sigma_\eta\}$, M_k 的先验分布为 p_{M_k} , β 的先验分布为伽玛分布; $\boldsymbol{\eta} = \{\eta_i, i=1, \dots, n\}$ 为考虑个体差异性而引入的随机效应参数集; η_i 对应的概率分布为对数正态分布, 且其对应的超参数为 μ_η 和 σ_η ; 超参数 μ_η 和 σ_η 的先验分布分别为正态分布和对数正态分布。

对于其他维修情形下采用不同模型建模时, 故障时间数据的模型及模型参数的后验分布, 可采用式(2-43)的方法来进行类比构建, 此处不再赘述。

4) 模型和模型参数后验分布的求解

在获得模型和模型参数后验分布之后, 该后验分布的求解成为故障时间数据

分析和机床可靠性评估的关键所在。对于没有解析解的后验分布，其求解的关键在于从该后验分布中抽取模型及模型参数的样本，并采用对样本进行统计归纳的方法来得到后验分布的概率分布以及统计特征量，如核密度（Kernel Density）、均值、方差和分位点等^[117-119]。在贝叶斯方法中后验分布的抽样主要采用马尔科夫链蒙特卡洛方法（Markov Chain Monte Carlo, MCMC）^[121-123]，其中又以 Metropolis-Hastings 抽样方法^[123]和 Gibbs 抽样方法^[124]应用较多。基于 Gibbs 方法已经开发出了较为成熟的建模和计算软件^[125]，如 WinBUGS（OpenBUGS）软件^{[126][127]}等。关于 MCMC 的基本原理和方法不再介绍，本章将重点放在式(2-27)所示的模型和模型参数后验分布求解的软件实现上。

下面以完好维修情形下故障时间数据 $\{\Delta t, \alpha\}$ 基于贝叶斯模型综合方法的建模与求解实现为例，详细介绍本文所构建的模型与模型参数估计在 OpenBUGS 软件中的求解实现。该求解流程主要包括模型集的构造、模型先验分布的给定、模型参数先验分布的给定以及故障时间数据似然函数的构建等四个关键环节。下面首先给出该参数估计方法在 OpenBUGS 中的实现，如图 2-5 所示；然后结合 OpenBUGS 中的实现对所使用方法的四个关键环节进行一一解释说明。

环节（1）：模型集

该数据的建模模型集由威布尔分布模型、对数正态分布模型与伽玛分布模型三个模型组成。

环节（2）：模型的先验分布

三个模型的的先验分布采用式(2-28)所示的形式，对应于图 2-5 中的 $M \sim \text{dcat}(p[])$ ，其中： M 为模型指示变量，当 M 取 1、2 和 3 时分别对应于选择威布尔分布模型、对数正态分布模型与伽玛分布模型来对数据进行建模分析。这一选择体现在该算法中似然函数 $\log\text{Like}[M, i, j]$ 中系数 M 的使用。 $p[]$ 为三个模型的先验分布概率，且有 $p[1] < -\text{prior1}$ 、 $p[2] < -\text{prior2}$ 和 $p[3] < -\text{prior3}$ ， prior1 至 prior3 的取值分别对应于式(2-28)中 p_1 至 p_3 的取值。

环节（3）：模型参数的先验分布

对于式(2-30)所示的威布尔分布模型，形状参数 β_i 和尺度参数 η_i 分别对应于图 2-5 中的 beta_wbl 和 $\text{yita_wbl}[i]$ ，其中：形状参数没有考虑机床样本差异性，即有 $\beta_1 = \beta_2 = \beta_3$ 且其先验分布为伽玛分布；尺度参数为考虑机床样本差异性的参数，在图 2-5 中为来自于对数正态分布的一组值，并且对数正态分布的参数（超参数） $\mu_{\text{yita_wbl}}$ 和 $\sigma_{\text{yita_wbl}}$ 的先验分布分别为正态分布和对数正态分布。

```

model{
#####模型的先验分布#####
M ~ dcat(p[]) ##M 为模型指示变量
p[1] <- prior1 ##第一个模型：威布尔分布模型的先验分布
p[2] <- prior2 ##第二个模型：对数正态分布模型的先验分布
p[3] <- prior3 ##第三个模型：伽玛分布模型的先验分布
#####模型参数的先验分布#####
# 威布尔分布模型参数的先验分布
beta_wbl ~ dgamma(a1_wbl, b1_wbl)
# 尺度参数 yita_wbl 的随机效应模型（对数正态分布）对应超参数的先验分布
mu_yita_wbl ~ dnorm(a2_wbl, b2_wbl)
sigma_yita_wbl ~ dlnorm(a3_wbl, b3_wbl)
# 对数正态分布模型参数的先验分布
sigma_logn ~ dlnorm(a1_logn, b1_logn)
# 均值参数 mu_logn 的随机效应模型（正态分布）对应超参数的先验分布
mu_mu_logn ~ dnorm(a2_logn, b2_logn)
sigma_mu_logn ~ dlnorm(a3_logn, b3_logn)
# 伽玛分布模型参数的先验分布
tau_gam ~ dgamma(a1_gam, b1_gam)
# 尺度参数 nu_gam 的随机效应模型（伽玛分布）对应超参数的先验分布
tau_nu_gam ~ dgamma(a2_gam, b2_gam)
nu_nu_gam ~ dlnorm(a3_gam, b3_gam)
#####数据的似然函数#####
for (i in 1:n){ # n 个装备样本
# 威布尔分布尺度参数 yita 的随机效应
yita_wbl[i] ~ dlnorm(mu_yita_wbl, sigma_yita_wbl)
# 对数正态分布均值参数 mu_logn 的随机效应
mu_logn[i] ~ dnorm(mu_mu_logn, sigma_mu_logn)
# 伽玛分布尺度参数 nu_gam 的随机效应
nu_gam[i] ~ dgamma(tau_nu_gam, nu_nu_gam)
for (j in 1:m[i]){ # 第 i 个装备样本对应 m[i] 个观测值 delta_t[i, j]
# 基于模型指示变量 M 的通用似然函数表达式
dummy[i, j] <- 0
dummy[i, j] ~ dloglik(alpha[i, j] * logLike[M, i, j])
# 威布尔分布的似然函数
logLike[1, i, j] <- log(beta_wbl / yita_wbl[i]) + (beta_wbl-1) * log(delta_t[i, j] /
yita_wbl[i]) + (-pow(delta_t[i, j] / yita_wbl[i], beta_wbl))
# 对数正态分布的似然函数
logLike[2, i, j] <- -log(delta_t[i, j] * sigma_logn) - 0.5*log(6.28) -
(pow((log(sigma_logn) - mu_logn[i]), 2) / 2 / pow(sigma_logn, 2))
# 伽玛分布的似然函数
logLike[3, i, j] <- - tau_gam * log(nu_gam[i]) - loggam(tau_gam) + (tau_gam -
1) * log(delta_t[i, j]) + (- delta_t[i, j] / nu_gam[i])
}
}
}
}

```

图 2-5 模型与模型参数估计在 OpenBUGS 软件中的求解实现

对于式(2-31)所示的对数正态分布模型,均值参数 μ_i 和方差参数 σ_i 分别对应于图 2-5 中的 $\mu_logn[i]$ 和 σ_logn , 其中: 方差参数没有考虑机床样本差异性, 即有 $\sigma_1 = \sigma_i = \sigma_n$ 且其先验分布为对数正态分布; 均值参数为考虑机床样本差异性的参数, 在图 2-5 中为来自于正态分布的一组值, 并且正态分布的参数(超参数) μ_mu_logn 和 σ_mu_logn 的先验分布分别为正态分布和对数正态分布。

对于式(2-32)所示的伽玛分布模型,形状参数 τ_i 和尺度参数 ν_i 分别对应于图 2-5 中的 τ_gam 和 ν_gam , 其中: 形状参数没有考虑机床样本差异性, 其先验分布为对数伽玛分布; 尺度参数为考虑机床样本差异性的参数, 在图 2-5 中为来自于伽玛分布的一组值, 并且伽玛分布的参数(超参数) τ_nu_gam 和 ν_nu_gam 的先验分布分别为伽玛分布和对数正态分布。

环节(4): 故障时间数据的似然函数

故障时间数据 $\{\Delta\mathbf{t}, \boldsymbol{\alpha}\}$ 对应于图 2-5 中的 $\delta\mathbf{t}[i, j]$ 和 $\alpha[i, j]$ 序列。似然函数的构建是通过循环描述各数据点 $\delta\mathbf{t}[i, j]$ 和 $\alpha[i, j]$ 所对应的各模型下的的概率密度函数的对数表达式来完成的。 $\log\text{Like}[M, i, j]$ 为基于模型指示变量 M 的通用似然函数, 当 M 取不同的值 1、2 或 3 时则对应于不同模型下数据点 $\delta\mathbf{t}[i, j]$ 的似然函数表达式。

6) 可靠性特征量后验分布的表征和求解

基于式(2-27)所给出的模型及模型参数后验分布的表达式, 可靠性特征量 X 的贝叶斯模型综合后验分布可表示为:

$$p(X | \mathbf{t}, \boldsymbol{\alpha}) = \sum_{k=1}^K \int_{\boldsymbol{\theta}_k} f(X | \boldsymbol{\theta}_k, M_k) p(\boldsymbol{\theta}_k, M_k | \mathbf{t}, \boldsymbol{\alpha}) d\boldsymbol{\theta}_k \quad (2-44)$$

式中, $f(X | \boldsymbol{\theta}_k, M_k)$ 表示在模型 M_k 下可靠性特征量 X 与模型参数 $\boldsymbol{\theta}_k$ 的函数关系。

在此继续以完好维修情形下, 故障时间数据 $\{\Delta\mathbf{t}, \boldsymbol{\alpha}\}$ 在 M_k 为威布尔分布模型时为例, 可靠性特征量 MTBF 的贝叶斯模型综合后验分布可表示为:

$$\text{MTBF}_i = \int \int_{\beta, \eta_i} \eta_i \Gamma(1 + 1/\beta) p(\beta, \eta_i, M_k | \Delta\mathbf{t}, \boldsymbol{\alpha}) d\beta d\eta_i \quad (2-45)$$

式中, MTBF_i 为第 i 个机床样本对应的 MTBF, $p(\beta, \eta_i, M_k | \Delta\mathbf{t}, \boldsymbol{\alpha})$ 为式(2-43)中边缘化其他模型参数后得到的后验分布。

式(2-44)的求解主要采用蒙特卡洛积分的方法。当采用 MCMC 方法获得模型 M_k 和模型参数 $\boldsymbol{\theta}_k$ 的后验分布的样本 $(\tilde{M}_k, \tilde{\boldsymbol{\theta}}_k)$ 之后, 将这些后验样本代入函数关系 $f(X | \boldsymbol{\theta}_k, M_k)$ 即可获得可靠性特征量的样本 \tilde{X} 。这些样本就是可靠性特征量后验分布的抽样, 通过对这些样本进行统计归纳, 即可获得可靠性特征量 X 的贝叶斯

模型综合评估，如核密度、均值、方差和分位点等的估计。

2.5 实例分析

在本节中，我们将上述模型与方法应用到某发电设备制造企业的某型重型数控机床的现场故障时间数据分析中。该企业内部自行开展的机床故障数据分析和可靠性评估，往往将所有的故障都计为关联故障并且都是在完好维修假设下进行的，所得出的评估结果与机床主机厂设计和承诺的可靠性指标相差甚远。本文将通过考虑维修程度、故障关联程度和模型不确定性的影响，对这些故障时间数据重新进行分析，以实现对该重型数控机床可靠性进行切实的评估。在此基础上，将本文模型和方法的评估结果与发电设备企业基于经典方法的评估结果进行对比，来对本文的模型和方法进行示例演示。

2.5.1 现场故障时间数据

本文所采用的现场故障时间数据来源于某发电设备制造企业在 2012 年 1 月至 2013 年 8 月间某型重型数控机床的停机维修记录，其中故障时间数据如表 2-1 所示。停机维修记录中具体的故障信息和维修信息受篇幅限制，在此不详细列出。该型重型数控机床为该发电设备制造企业的关键装备，任何机床的意外停机和故障都会造成生产任务的停止。在停机维修记录中所有机床的故障时间都得到了记录，其中既包含了关联故障所引起的停机又包含了非关联故障引起的停机。此外，考虑到重型数控机床的故障维修往往难以达到“修复如新”的效果，机床的修复中既包含了“修复如新”的完全维修，又包含了“修复如旧”的最小维修。

表 2-1 用户厂收集的故障时间数据

故障发生时间序列 (h)
0, 165, 183, 343, 587, 631, 1536, 1632, 2462, 2484, 4503, 4991, 5015, 5499, 5512, 5832, 5870, 5894, 5922, 6100, 6124, 6788, 6900, 6916, 7170, 7414, 7433, 7484, 8439, 8573, 8743, 9343, 9489, 9704, 9797, 9831, 10421, 10467, 10729, 11510, 11521, 11564, 11573, 11621

根据 2.2 节中故障判据的描述，结合该型重型数控机床的特性及其使用维护的要求，对停机维修记录中各故障发生的原因进行分析，将各故障的关联程度进行了详细的分析确定。在进行故障关联程度分析时，将其中由机床本身原因引起的故障，如零部件、元器件、软件等的故障所引起的故障停机都计为关联故障，其故障时间对应的故障关联因子 α 记为 1。在表 2-1 各故障时间点对应的故障停机中，

明确的关联故障主要包括：多头泵故障引起的多头泵压力低和 X 轴无法开动、限位开关故障引起的升降走台无动作、主轴拉爪变形引起的主轴松刀故障、电柜空调故障引起的驱动报警和主轴停转、冷油机循环电机烧坏引起的冷油机开关跳闸和机床报警停机、静压供油系统油管损坏引起的静压报警停机等。

与此同时，对于那些不是由机床本身原因引起的，而是由外在因素所造成的故障，如误操作故障、维修不当引起的故障、环境条件超出允许条件引起的故障、工作应力超出允许应力引起的故障都计为非关联故障，其故障时间对应的故障关联因子 α 记为 0。在表 2-1 各故障时间点对应的故障停机中，明确的非关联故障主要包括：U 轴超限位导致机床无法开动、Z 轴到达硬限位导致的 Z 轴报警停机、液压油站缺油引起的静压系统的停机、进刀量过大引起的主轴故障报警停机、识别开关未压好引起的附件识别故障停机、冷却液箱液位低引起的内冷故障停机等。

对于表 2-1 各故障时间点对应的故障停机中，部分故障由于无法明确的区分其是否属于关联故障或非关联故障，通过企业（用户厂）的维修人员会同机床制造厂（主机厂）的设计人员，就导致这些故障的原因进行分析讨论，并给出了 $[0,1]$ 区间上的故障关联因子 α （当 α 越大时，该故障属于关联故障的可能性越大）。这些不能明确区分是否为关联故障的比较典型的例子有：附件抓取压力低导致无法抓取附件停机、拉杆生锈卡涩导致延伸铣头无法复位、开关跳闸导致 X 轴开不动、分油器压力检测口堵塞导致的主轴润滑压力低报警停机、管道内有空气导致内冷故障停机、顶丝松动导致的附件脱落停机、润滑管路流量过大导致滑枕漏油停机等。

经过以上的故障关联程度的分析处理后，得到对应于表 2-1 中各故障时间点的故障关联因子。进一步将非关联故障所对应的故障时间点进行剔除，得到考虑故障关联程度的机床故障时间数据如表 2-2 所示。

表 2-2 考虑故障关联程度的重型镗铣床故障时间数据（单位：h）

故障关联因子	0.00	0.15	0.15	0.15	0.99	0.99	0.98	0.98	0.20
故障发生时间	0	165	343	587	1536	2462	4503	4991	5499
故障关联因子	0.23	1.00	0.98	0.96	0.21	1.00	0.21	0.98	1.00
故障发生时间	5832	5922	6100	6788	6900	7170	7414	8439	8573
故障关联因子	0.98	0.22	0.21	1.00	0.20	0.99	0.99	0.15	
故障发生时间	9343	9489	9704	10421	10729	11510	11564	11621	

2.5.2 考虑维修程度和故障关联程度的故障时间数据建模

对于表 2-2 所示的故障时间数据，其中对应故障的维修主要采用两种维修策略：完全维修和最小维修。在对该数据进行分析时，不能单独的假设其符合哪一种维修假设下的模型，需要同时应用多种模型来对其进行综合分析，这就需要采用基于贝叶斯模型综合分析的方法来对其进行建模。

根据 2.4 节中描述的基于贝叶斯模型综合的可靠性评估方法，首先需要确定故障时间数据的建模模型集。在完全维修假设下，用于数控机床故障时间数据建模的模型主要包括：威布尔分布模型（多以两参数的威布尔分布模型为主）、伽玛分布模型、对数正态分布模型和指数分布模型等。对于表 2-2 所示的故障时间数据，在完全维修假设下，应用这些模型对故障时间数据进行拟合得到对应的拟合结果分别如图 2-6 和表 2-3 所示。

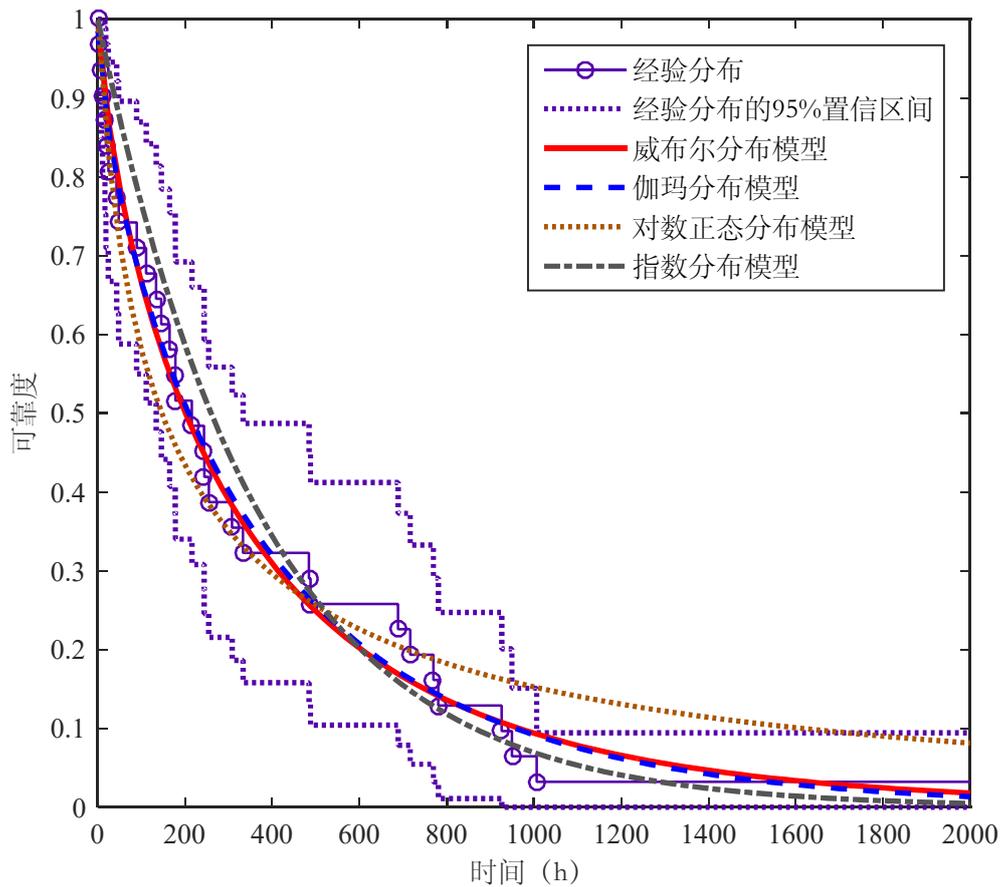


图 2-6 完全维修假设下多个模型的拟合结果

表 2-3 完全维修假设下多个模型的拟合结果及模型选择的 AIC 值

模型	威布尔分布模型	伽玛分布模型	对数正态分布模型	指数分布模型
参数估计	$\beta = 0.765,$ $\eta = 324.691$	$\tau = 0.651,$ $\nu = 575.622$	$\mu = 4.989,$ $\sigma = 1.871$	$\lambda = 0.002$
AIC	429.568	428.948	439.144	433.448

从拟合结果和 AIC 模型选择指标可以初步确定：威布尔分布模型和伽玛分布模型在完全维修假设下，能够对表 2-2 中的故障时间数据进行较好的建模。此外，在最小维修假设下，考虑到威布尔过程模型对应的故障强度函数能够描述多种不同类型的故障规律，在实际工程中最小维修假设下用于数控机床故障时间数据建模的模型主要为威布尔过程模型^[12, 18]。综上，选择威布尔分布模型、伽玛分布模型和威布尔过程模型来作为贝叶斯模型综合分析的模型集。令 M 为模型集中的模型变量： $M = 1$ 时为威布尔分布模型， $M = 2$ 时为伽玛分布模型， $M = 3$ 时为威布尔过程模型。

令 T 为龙门铣镗床发生故障的时间，在模型集中各模型下故障时间 T 分别建模如下：

1) 威布尔分布模型 ($M = 1$)

$$f(t|\beta, \eta) = \frac{\beta}{\eta} \left(\frac{t}{\eta}\right)^{\beta-1} \exp\left(-\left(\frac{t}{\eta}\right)^\beta\right) \quad (2-46)$$

$$\text{MTBF} = \eta \Gamma\left(1 + \frac{1}{\beta}\right) \quad (2-47)$$

2) 伽玛分布模型 ($M = 2$)

$$f(t|\tau, \nu) = \frac{t^{\tau-1} \exp(-t/\nu)}{\nu^\tau \int_0^\infty u^{\tau-1} e^{-u} du} \quad (2-48)$$

$$\text{MTBF} = \tau \nu \quad (2-49)$$

3) 威布尔过程模型 ($M = 3$)

$$f(t_i | t_{i-1}, \beta^{NH}, \eta^{NH}) = \frac{\beta^{NH}}{\eta^{NH}} \left(\frac{t_i}{\eta^{NH}}\right)^{\beta-1} \exp\left(-\left(\frac{t_i}{\eta^{NH}}\right)^{\beta^{NH}} + \left(\frac{t_{i-1}}{\eta^{NH}}\right)^{\beta^{NH}}\right) \quad (2-50)$$

式中， t_i 和 t_{i-1} 分别为第 i 和 $i-1$ 个故障发生的时刻。

$$\text{MTBF}_i = \frac{\eta}{\beta} \left(\frac{t_i}{\eta}\right)^{1-\beta} \quad (2-51)$$

式中, $MTBF_i$ 为机床在 t_i 时刻瞬时的平均故障间隔时间。

在确定了模型集的基础上, 进一步根据 2.3.2 节中描述的考虑故障关联程度的故障时间数据建模的方法, 结合式(2-46)、(2-48)和(2-50)所示的模型, 可将表 2-2 中的故障时间数据 \mathbf{t} 及故障关联信息 $\mathbf{\alpha}$ 通过似然函数分别描述为:

1) 威布尔分布模型下的似然函数

$$L(\mathbf{t}, \mathbf{\alpha} | \beta, \eta, M=1) = \prod_{i=2}^n \left(\frac{\beta}{\eta} \left(\frac{t_i - t_{i-1}}{\eta} \right)^{\beta-1} \exp \left(- \left(\frac{t_i - t_{i-1}}{\eta} \right)^{\beta} \right) \right)^{\alpha_i} \quad (2-52)$$

2) 伽玛分布模型下的似然函数

$$L(\mathbf{t}, \mathbf{\alpha} | \tau, \nu, M=2) = \prod_{i=2}^n \left(\frac{(t_i - t_{i-1})^{\tau-1} \exp \left(- \frac{t_i - t_{i-1}}{\nu} \right)}{\nu^{\tau} \int_0^{\infty} u^{\tau-1} e^{-u} du} \right)^{\alpha_i} \quad (2-53)$$

3) 威布尔过程模型下的似然函数

$$L(\mathbf{t}, \mathbf{\alpha} | \beta^{NH}, \eta^{NH}, M=3) = \prod_{i=2}^n \left(\frac{\beta^{NH}}{\eta^{NH}} \left(\frac{t_i}{\eta^{NH}} \right)^{\beta-1} \exp \left(- \left(\frac{t_i}{\eta^{NH}} \right)^{\beta^{NH}} + \left(\frac{t_{i-1}}{\eta^{NH}} \right)^{\beta^{NH}} \right) \right)^{\alpha_i} \quad (2-54)$$

根据 2.4 节中描述的关于各模型下基于贝叶斯方法的模型参数估计方法, 在获得观测信息的似然函数的同时, 需要确定模型及模型参数的先验分布。在对表 2-2 所示的故障时间数据分析时, 主机厂和用户厂处没有可用的先验信息。此时, 对于模型的先验分布, 即采用式(2-28)所示的类别分布 (Categorical Distribution) 且有 $\pi(M=1) = \pi(M=2) = \pi(M=3) = 1/3$ 。对于各模型下模型参数的先验分布采用均匀分布来对故障数据进行分析, 通过结合各参数的物理特性及其对应的取值范围来选取较大区间上的均匀分布。各模型参数对应均匀分布如表 2-4 所示, 其中形状参数如 β 、 τ 和 β^{MH} 选用 $[0,10]$ 上的均匀分布, 而尺度参数如 η 、 ν 和 η^{MH} 则选用 $[0,5000]$ 上的均匀分布。

在获得了模型和模型参数的先验分布以及故障时间数据在各模型下的似然函数之后, 即可应用 2.4.2 节中描述的基于贝叶斯模型综合的故障数据分析方法, 将模型的先验分布、各模型下模型参数的先验分布以及故障时间数据 \mathbf{t} 及故障关联信息 $\mathbf{\alpha}$ 的似然函数代入式(2-27), 可得模型集中模型和各模型参数的联合后验分布:

$$p(\theta_k, M_k | \mathbf{t}, \mathbf{\alpha}) = \frac{L(\mathbf{t}, \mathbf{\alpha} | \theta_k, M_k) \pi(\theta_k | M_k) \pi(M_k)}{\sum_{k=1}^3 \int_{\theta_k} L(\mathbf{t}, \mathbf{\alpha} | \theta_k, M_k) \pi(\theta_k | M_k) \pi(M_k) d\theta_k} \quad (2-55)$$

式中， $\theta_1 = \{\beta, \eta\}$ ， $\theta_2 = \{\tau, \nu\}$ ， $\theta_3 = \{\beta^{MH}, \eta^{MH}\}$ ； $L(\mathbf{t}, \boldsymbol{\alpha} | \theta_k, M_k)$ 对应于上文给出的各模型下的似然函数。

对于模型和模型参数联合后验分布的求解，根据图 2-5 描述的 MCMC 抽样算法的 OpenBUGS 实现，利用 OpenBUGS 对后验分布抽样，并在此基础上获得模型和模型参数的估计结果如表 2-4 所示。从表中参数估计的结果可知：在获得模型参数估计的同时，也获得了各模型的后验概率的估计；最小维修下的威布尔过程模型要比完全维修下的威布尔分布模型和伽玛分布模型的后验概率要高；模型参数对应的后验置信区间都包含在所用的先验分布的区间之内，均匀分布的区间并没有对模型参数的抽样产生限制，从而达到了无信息先验的目的。

表 2-4 模型和模型参数的估计结果

模型参数	统计特征值		后验置信区间		模型先验分布
	均值	方差	2.5%	97.5%	
β	0.8034	0.1396	0.5487	1.094	Uniform(0,10)
η	505.7	155.1	270.6	872.4	Uniform(0,5000)
τ	0.6679	0.1689	0.373	1.045	Uniform(0,10)
ν	914.5	448.3	418.9	2112	Uniform(0,5000)
β^{NH}	1.4	0.2167	0.9968	1.841	Uniform(0,10)
η^{NH}	1089	411.3	381.3	1971	Uniform(0,5000)
$\Pr(M=1)$	0.2209	0.4447	0	1	1/3
$\Pr(M=2)$	0.2715	0.4149	0	1	1/3
$\Pr(M=3)$	0.5076	0.4999	0	1	1/3

2.5.3 可靠性评估及结果分析

当获得模型集中模型及模型参数的后验样本之后，即可根据各模型下对应可靠性特征量的表达式，来获得多模型综合下的可靠性特征量的估计值。本文主要研究平均故障间隔时间这一可靠性特征量在多模型综合下的评估。

根据模型集中模型后验分布的 MCMC 抽样可得，威布尔分布模型、伽玛分布模型和威布尔过程模型的后验概率如表 2-4 所示，同时后验样本分布情况如图 2-7 所示。在此基础上，进一步结合各模型下模型参数后验分布的 MCMC 抽样和 MTBF 的计算公式，可以得到多模型综合下 MTBF 的估计值如图 2-8 所示。图中的 MTBF 为不同时间点 MTBF 的瞬时值，这是因为在最小维修情形下 MTBF 的值是随着服役时间的变化而动态变化的，所获得的 MTBF 并不是严格意义上的平均故障时间

而是对应于某一时刻的瞬时平均故障时间。

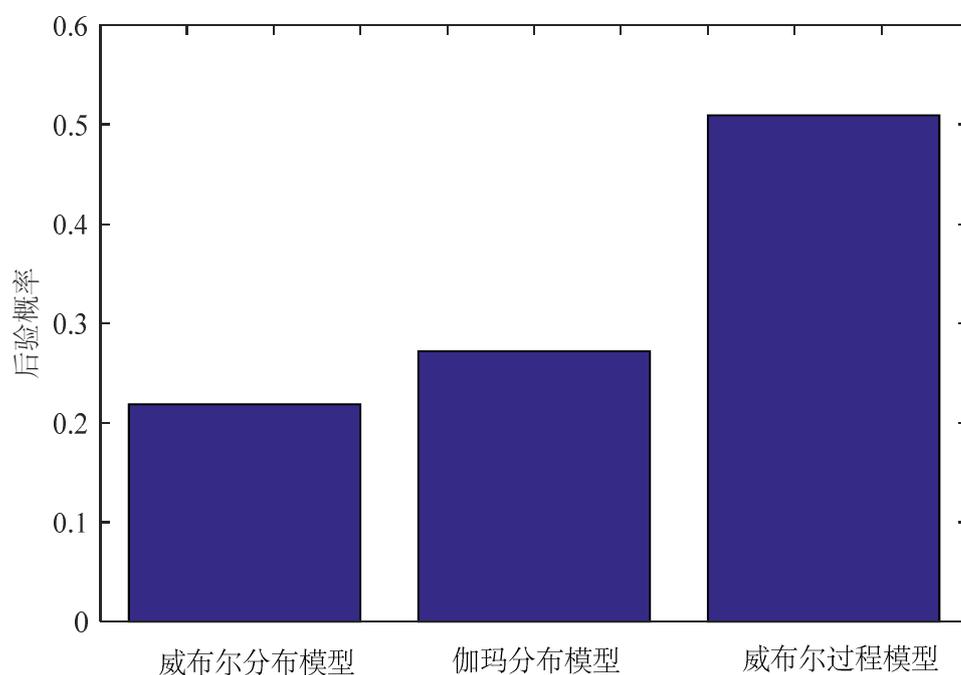


图 2-7 模型变量 M 的后验分布

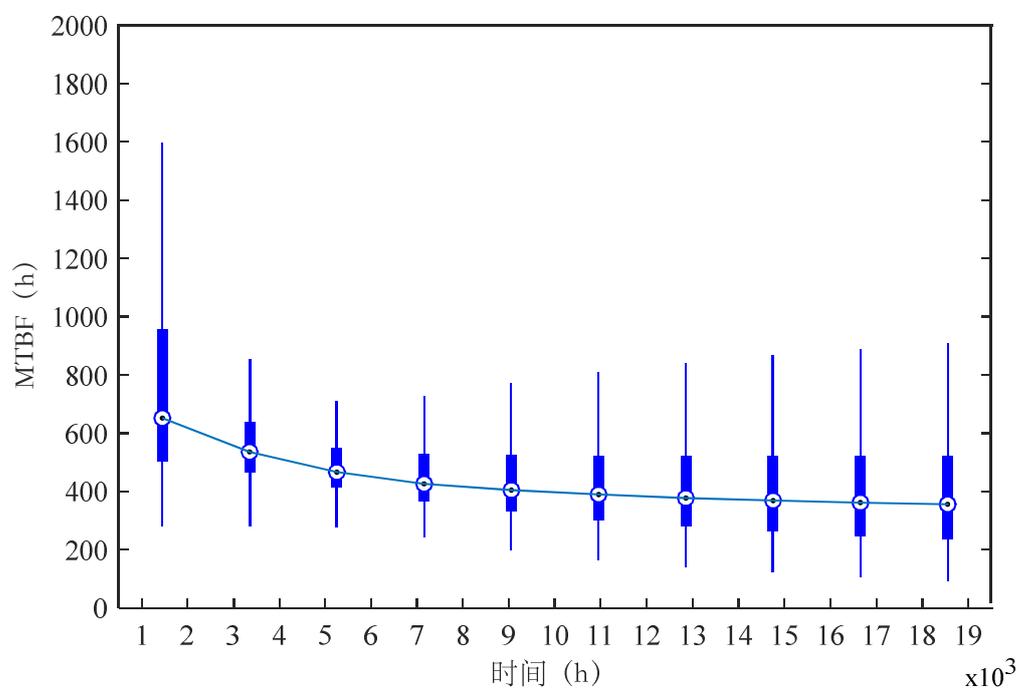


图 2-8 考虑维修程度和故障关联程度的 MTBF 估计值

从图中可以看出，随着机床服役时间的增加 MTBF 逐渐由服役时间 1000h 的

瞬时 MTBF = 652h 逐渐递减到 19000h 的瞬时 MTBF = 350h。在服役时间 1000h 到 5000h 的区间范围内瞬时 MTBF 降低的速度较快，在服役时间 13000h 到 19000h 的区间范围内瞬时 MTBF 降低速度较慢且相对较为稳定。该分析结果一方面反映了表 2-2 中故障时间序列数据所体现出来的重型数控机床的可靠性特征，另一方面也符合当前机床的实际情况并得到了主机厂和用户厂专家的肯定。

在此基础上，进一步对比本文的分析结果与该发电设备制造企业在完好维修假设下不考虑故障关联程度时的分析结果。企业分析评估得到的 MTBF 结果如图 2-9 所示。从图中可知，企业评估所得的 MTBF 并不随着服役时间的变化而动态变化，且从由服役时间 1000h 到服役时间 19000h 之间机床的 MTBF 始终都保持为 270h。这一分析结果一方面与图 2-8 的分析结果存在较大的偏差，这是因为非关联故障的计入和完全维修的假设使得 MTBF 的评估结果异常偏低；另一方面与机床主机厂进行机床设计制造和装配后交付时的 MTBF 验证值相差甚远，其评估结果并不能反映该型重型数控机床可靠性的真实情况。

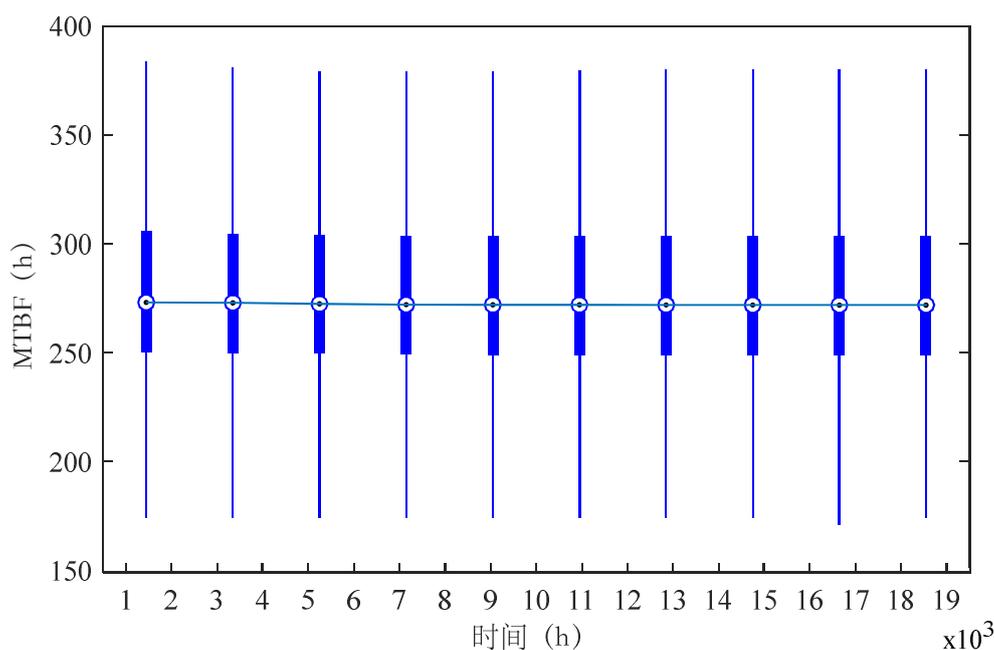


图 2-9 不考虑维修程度和故障关联程度的 MTBF 估计值

综合以上的分析和对比可知：表 2-1 中机床的故障时间序列数据同时包含了完好维修和最小维修情形下产生的故障数据，且最小维修情形下产生的故障数据比例较大。在对该数据进行分析时，需要考虑各时间点对应故障的故障关联程度，当忽略故障关联程度时将会导致评估结果偏低。本文所提出的模型和方法能对机床的故障时间数据进行有效分析，机床的瞬时 MTBF 随着服役时间的增加而逐渐

递减，在初始时段区间（1000h 到 5000h）机床的瞬时 MTBF 降低的速度较快，随后逐渐趋于稳定的状态。

2.6 本章小结

本章针对重型数控机床在多因素的影响下其故障时间数据并非独立同分布，并且难以采用单一概率分布模型对其进行全面建模与评估的问题，从考虑维修程度、故障关联程度和模型不确定三个方面，研究了重型数控机床基于故障时间数据的可靠性建模与评估方法。首先系统地研究了完好维修、非完好维修和最小维修情形下的机床故障时间数据的模型。在此基础上，通过引入故障关联因子对故障时间数据的模型进行修正，实现故障关联程度在故障时间数据模型中的建模描述。然后，研究了基于贝叶斯模型综合方法的模型参数估计与可靠性评估方法，以实现模型不确定性的综合量化与表达。在此基础上，解决了对重型数控机床故障时间数据分析中的维修程度、故障关联和模型不确定性三方面的问题。最后，通过实例分析对本文所提出的模型和方法进行了示例应用。从实例分析中可知：维修程度的考虑对数据建模的要求较高，故障时间数据的建模需要同时综合不同维修程度下的多个模型才能对其进行全面的建模描述；故障关联程度对评估结果的影响较大，当不考虑故障时间数据中故障的关联程度时，将会导致评估结果的偏差较大并与实际情况相背离；贝叶斯模型综合方法具有较强的评估能力，能够妥善满足考虑维修程度和故障关联程度的多模型综合评估的实际要求。

第三章 基于多源层次信息集的重型数控机床可靠性建模与评估

随着重型数控机床寿命周期可靠性工作的开展，机床可靠性建模与评估逐渐由整机级的“宏观”分析，逐渐向考虑系统层级结构的“深度”分析演进。这就需要对多源层次信息集进行建模分析，并在此基础上对机床可靠性进行评估。多源层次信息集是指那些来自于不同信息源并分布在系统不同层次的可靠性信息的集合。这类信息集一方面具有信息和数据多样性的特点，如专家经验信息、成败型故障数据、寿命型故障数据和退化型数据等；另一方面具有信息和数据覆盖性的特点以及数据融合性的要求。此时，基于故障时间数据的可靠性建模与评估方法已经难以适用，而基于多源层次信息集的建模与评估成为亟待解决的难题。因此，本章将在传统基于成败型、寿命型和退化型数据的可靠性建模与评估的基础上，应用贝叶斯多源信息融合与贝叶斯网络理论，构建重型数控机床基于多源层次信息集的可靠性建模与评估方法，为机床寿命周期多阶段的可靠性建模与评估提供技术支撑。

3.1 引言

近年来，随着国家中长期科学和技术发展规划纲要（2006-2020年）逐渐展开和落实，特别是国家科技重大专项“高档数控机床与基础制造装备”的实施和推进，重型数控机床可靠性技术的研究与应用也得到了大力的推进。重型数控机床可靠性的研究，由现场故障数据的采集与分析等“事后行为”，逐渐向研制阶段的可靠性试验和可靠性增长等“事前行为”发展。在关注整机可靠性的同时，也逐渐将关键子系统和关键功能部件的可靠性纳入了研究范畴，并逐步搭建相应的台架试验设备和可靠性数据收集平台。在这样的环境和条件下，重型数控机床的可靠性信息也逐渐由整机级的寿命型数据，如售后维修数据和现场故障数据等，逐渐向涉及多系统层次的多类型的可靠性信息集发展，如零部件、功能部件、子系统和整机等多系统层次的成败型、寿命型以及性能退化型的可靠性信息集。为了对机床的可靠性进行全面量化，需要将来自于不同信息源并分布在不同层次的可靠性信息进行建模融合。对于这样的问题，一方面考虑系统层次结构的可靠性建模，可为零部件、功能部件和子系统对机床整机可靠性的影响识别提供可靠性模型的支撑；另一方面，融合多源层次信息的可靠性评估，可为机床可靠性的增长和验证提供量化信息的支撑。目前，机床可靠性建模与评估的研究主要集中在单一信息来源和单一系统层次的可靠性建模与评估上，针对多源层次信息集的可

可靠性建模与评估研究较少。其根本原因在于：1) 多源层次信息集的建模难度较大，需要逐步构建具有不同信息类型特征并分布在系统不同层次的可靠性信息的模型；2) 模型参数估计和可靠性融合评估难度较大，需要全面融合多源层次信息集的数据和信息并对整机的可靠性给出高置信度的评价。因此，本章将在传统可靠性建模与评估方法的基础上，对重型数控机床基于多源层次信息集的可靠性建模与评估方法展开研究，一方面为机床的可靠性建模与评估的理论研究进行拓展，另一方面为机床寿命周期可靠性工作的开展提供技术支撑。

3.2 重型数控机床的多源层次信息集

重型数控机床的多源层次信息集是随着数控机床寿命周期可靠性工作的开展而逐渐形成和积累起来的，同时也是机床在研制阶段对定型样机和试制样机的可靠性进行评估确认所依赖的关键信息集。多源是指可靠性信息的来源有多种，对于重型数控机床而言主要包括：同型号机床的历史可靠性信息、设计研制人员的专家经验信息、机床可靠性试验数据、机床现场故障数据以及使用维修人员的经验信息等。这些信息可能是针对机床整机的可靠性信息，同时也可能是针对机床的子系统、功能部件和零部件的可靠性信息。

同型号机床的历史可靠性信息主要是指与当前机床具有相同的结构、功能形式且在关键子系统和关键功能部件上有共同之处的机床以往的可靠性信息。例如，系列产品中某些旧型号机床的可靠性信息可以作为新型号机床的历史可靠性信息，特别是采用了相同的机床平台、子系统、功能部件和零部件的旧型号机床的可靠性信息。这些历史可靠性信息主要以客观数据的形式表现为机床整机的可靠性评估结果以及子系统、功能部件和零部件的故障数据，如同型号机床整机和对应平台、子系统、功能部件和零部件的售后维修数据、现场故障数据以及这些数据经过处理之后得到的整机和对应部件的 MTBF 信息。这一类信息需要采用层次信息建模和融合的方法来对其进行有效地处理。

设计研制人员的专家经验信息主要是指在机床设计和研制阶段，专家经历机床的方案、初样、试样、试制、定型等多个环节，综合机床在设计、优化、试验等多个方面产生的关于机床可靠性方面的总体认知。例如机床总体组专家或者分管质量的总设计师对当前机床总体可靠性的主观评价等。这些设计研制人员的专家经验信息主要以主观信息的形式，表现为机床整机或关键子系统可靠性的主观评价，如“当前型号机床的可靠性将比上一代机床在整体上有 10% 的提升”。这一类信息需要采用主观信息量化与融合的方法来对其进行有效地处理。

机床的可靠性试验数据主要是指机床在设计和研制阶段，针对机床的整机、

关键子系统、功能部件和零部件开展的相应的仿真试验、性能试验和可靠性试验，并对相应的数据进行初步处理后与机床可靠性相关联的试验数据。随着重型数控机床寿命周期可靠性技术的发展，机床在设计和研制阶段的可靠性试验逐步得到实施，已经逐渐与仿真试验和性能试验并列为同等重要的试验。这些机床的可靠性试验数据主要以客观数据的形式表现为整机、关键子系统、功能部件和零部件的成败型、寿命型或者性能退化型的可靠性试验数据。这一类信息需要采用针对不同数据类型的层次信息建模和融合的方法来对其进行有效地处理。

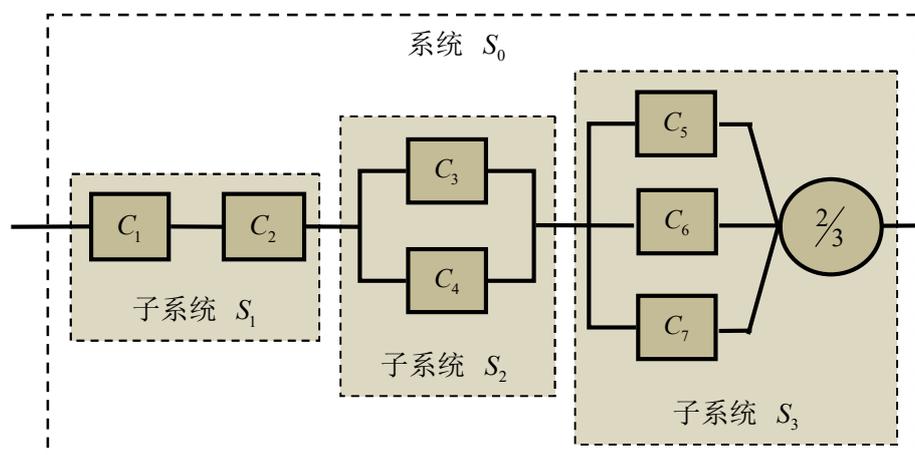
机床现场故障数据主要是指机床在服役阶段根据机床售后维修信息和现场跟踪所采集到的可靠性数据。机床现场故障数据是随着主机厂售后管理体系的完善和用户厂对机床运行、维护和管理规范化而逐渐积累起来的。这些机床的现场故障数据以客观数据的形式表现为整机的故障时间数据并受到故障的关联关系和机床的维修程度所影响。这一类信息需要考虑故障关联程度和维修程度的故障时间数据的建模与分析方法来对其进行有效地处理。

机床使用和维修人员的经验信息主要是指服役阶段的机床使用和维修人员在经历了机床的调试、运行、维护、维修等多个环节之后，对机床整机的运行可靠性或者对关键子系统和功能部件可靠性的经验性认知。这些机床使用和维修人员的经验信息与设计研制人员的专家经验信息相类似，都主要以主观信息的形式表现为机床整机可靠性的主观评价。两者主要的区别在于前者是对机床在服役阶段使用可靠性的主观认知，后者是对机床设计和研制阶段固有可靠性的主观认知。这一类信息需要采用主观信息量化与融合的方法来对其进行有效地处理。

综合以上对重型数控机床多源层次信息的来源以及相应特性的分析，可以得出机床基于多源层次信息的可靠性建模与评估需要解决的两个技术关键点如下：1) 全面的系统可靠性建模框架：该框架能够实现同时建立具有不同可靠性数据特性且分布在系统不同层次的零部件、功能部件、子系统以及整机的可靠性模型，依托该模型框架将实现多源层次信息的建模描述；2) 综合的主客观信息融合方法：该方法能够实现多种主客观信息的量化与融合，并依托融合方法可实现基于多源层次信息的融合评估。针对这两个技术关键点，本章拟开展重型数控机床的多源层次信息建模技术的研究和基于混合贝叶斯网络的重型数控机床多源层次信息融合技术研究。

本文以图 3-1 所示的系统为例来对基于多源层次信息的机床可靠性建模与评估的方法来进行描述。该系统分为系统级、子系统级和部件级三个层次。系统 S_0 由 3 个子系统 S_1 、 S_2 和 S_3 以串联结构形式构成，子系统 S_1 则由部件 C_1 和 C_2 以串联形式构成，子系统 S_2 由部件 C_3 和 C_4 以并联形式构成，子系统 S_3 由部件 C_5 、 C_6 和 C_7

以 3 中取 2 的表决结构形式构成。系统各层次所对应的可靠性信息结构为：系统级和子系统级的可靠性信息主要以寿命型的客观信息和经验评价型的主观信息为主，部件级的可靠性信息主要包括成败型、寿命型和退化型的客观信息以及经验评价型的主观信息为主。



系统级 S_0 ：寿命型数据和主观经验信息

子系统级 S_1 、 S_2 和 S_3 ：寿命型数据和主观经验信息

部件级 C_1 至 C_7 ： C_1 和 C_2 为成败型数据和主观经验信息；

C_3 和 C_4 为寿命型数据和主观经验信息；

C_5 为成败型数据， C_6 为寿命型数据， C_7 为退化型数据，以及各自对应的主观经验信息。

图 3-1 系统的可靠性框图及其对应的多源层次信息集

3.3 重型数控机床多源层次信息集的可靠性建模

系统可靠性建模是多源层次信息融合的关键基础，一方面需要妥善解决系统层次结构的建模问题，另一方面需要解决多种类型可靠性信息的建模问题。本节针对这两个关键问题，首先给出机床考虑多源层次信息集的可靠性建模基本框架，然后在该基本框架下分别研究层次系统的建模问题和多种类型可靠性数据的建模问题。

3.3.1 可靠性建模框架

重型数控机床考虑多源层次信息集的可靠性建模基本框架如图 3-2 所示。该框架主要包括两大部分：1) 系统层次结构的可靠性建模；2) 系统多种类型可靠性信息的建模。系统层次结构的可靠性建模的核心在于利用零部件的参数化可靠性模型，以子系统和系统等高层节点所对应的结构函数为纽带，由底层向高层次逐步“替代”建模。系统多种类型的可靠性信息建模的核心在于以现有成败型、寿

命型和退化型数据的建模为基础，以可靠性模型与数据模型中的时间变量为连接纽带，由单数据模型向多数据模型逐步“组合”建模。

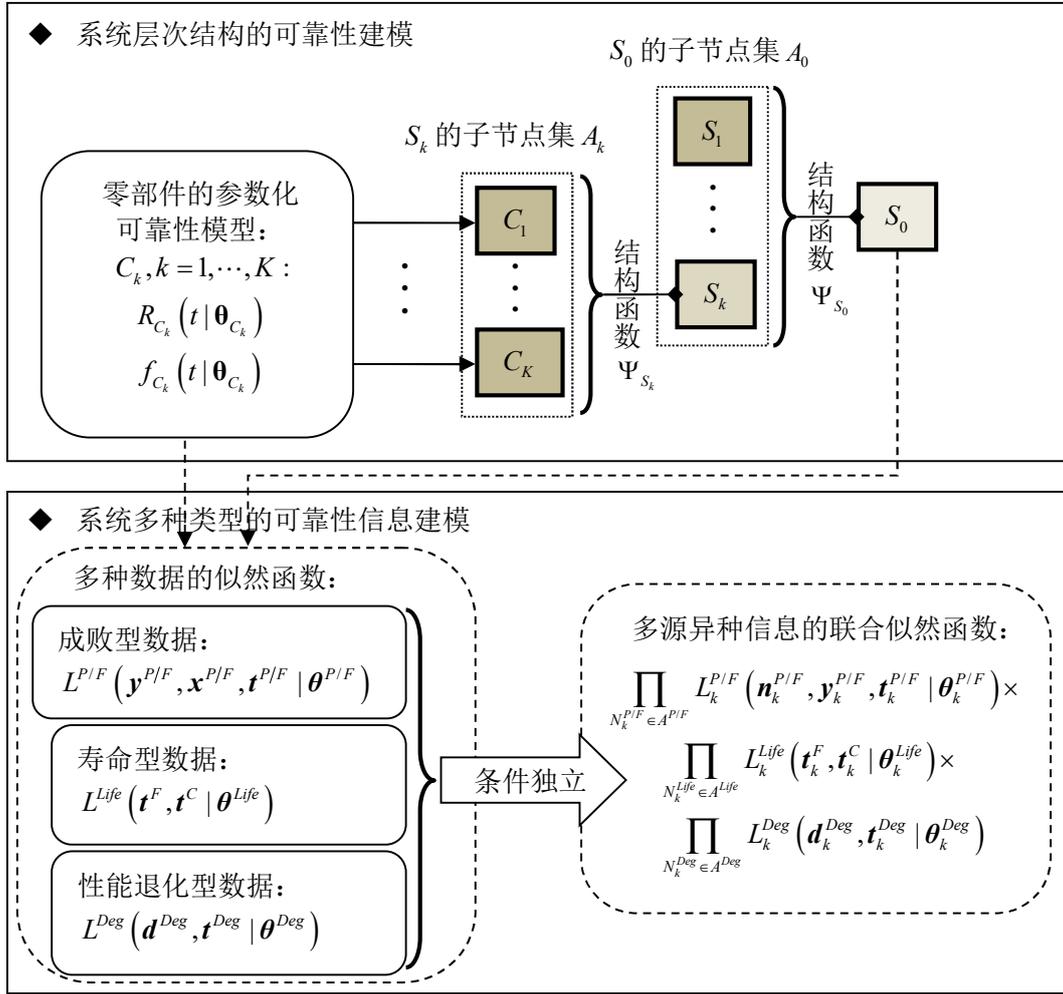


图 3-2 考虑多源层次信息集的可靠性建模基本框架

在本文建模方法的描述过程中将会使用到以下系统结构性相关的术语和符号。系统不同层次的部分如系统、子系统、功能部件和零部件统一称为系统中的节点，例如图 3-1 中的 S_0 ， S_1 至 S_3 以及 C_1 至 C_7 都为该系统中的节点。构成系统中某一节点 S_i 的所有低一层子节点的集合称为 S_i 的子节点集 A_i ，如图 3-1 中 S_0 的子节点集为 $A_0 = \{S_1, S_2, S_3\}$ 。节点 S_i 与其子节点之间的可靠性关系通过结构函数 Ψ_{A_i} 来进行描述。

3.3.2 系统层次结构的可靠性建模

\bar{n} 系统层次结构的可靠性建模是通过采用逐步“替代”的策略所建立的。这种策略可描述为：高层节点 S_k 的可靠性模型可以通过其对应的结构函数 Ψ_{A_k} ，表示

成子节点集 A_k 中对应节点的可靠性模型的函数关系式:

$$\begin{aligned}
 R_{S_k}(t|\boldsymbol{\theta}_{S_k}) &= \Psi_{S_k}(R_{S_l}, R_{C_l} : \forall S_l \in A_k, \forall C_l \in A_k) \\
 f_{S_k}(t|\boldsymbol{\theta}_{S_k}) &= - \sum_{\forall S_l \in A_k} \frac{\partial R_{S_k}}{\partial R_{S_l}} \frac{dR_{S_l}(t|\boldsymbol{\theta}_{S_l})}{dt} - \sum_{\forall C_l \in A_k} \frac{\partial R_{S_k}}{\partial R_{C_l}} f_{C_l}(t|\boldsymbol{\theta}_{C_l})
 \end{aligned} \quad (3-1)$$

式中, $R(t|\boldsymbol{\theta})$ 和 $f(t|\boldsymbol{\theta})$ 分别为节点的可靠度函数和故障概率密度函数, $\boldsymbol{\theta}$ 为对应节点的可靠性模型参数。

以图 3-1 为例, 系统 S_0 以及子系统 S_1 至 S_3 的可靠度函数可通过以上的建模方法描述为:

$$\begin{aligned}
 R_{S_0}(t_{S_0}|\boldsymbol{\theta}_{S_0}) &= (\min(t_{S_1}, t_{S_2}, t_{S_3}) | R_{S_1}(t_{S_1}|\boldsymbol{\theta}_{S_1}), R_{S_2}(t_{S_2}|\boldsymbol{\theta}_{S_2}), R_{S_3}(t_{S_3}|\boldsymbol{\theta}_{S_2})) \\
 R_{S_1}(t_{S_1}|\boldsymbol{\theta}_{S_1}) &= (\min(t_{C_1}, t_{C_2} | R_{C_1}(t_{C_1}|\boldsymbol{\theta}_{C_1}), R_{C_2}(t_{C_2}|\boldsymbol{\theta}_{C_2}))) \\
 R_{S_2}(t_{S_2}|\boldsymbol{\theta}_{S_2}) &= (\max(t_{C_3}, t_{C_4}) | R_{C_3}(t_{C_3}|\boldsymbol{\theta}_{C_3}), R_{C_4}(t_{C_4}|\boldsymbol{\theta}_{C_4})) \\
 R_{S_3}(t_{S_3}|\boldsymbol{\theta}_{S_2}) &= \left(\begin{array}{c} \max(\min(t_{C_5}, t_{C_6}), \min(t_{C_6}, t_{C_7}), \min(t_{C_5}, t_{C_7})) \\ R_{C_5}(t_{C_5}|\boldsymbol{\theta}_{C_5}), R_{C_6}(t_{C_6}|\boldsymbol{\theta}_{C_6}), R_{C_7}(t_{C_7}|\boldsymbol{\theta}_{C_7}) \end{array} \right)
 \end{aligned} \quad (3-2)$$

式中, $\boldsymbol{\theta}_{S_0}$ 包含了系统中所有节点对应可靠性模型的所有参数。

式(3-2)所示的系统 S_0 以及子系统 S_1 至 S_3 的可靠度函数是在一般情形下的表达式。当部件之间或子系统之间存在相关性时, 高层节点的可靠度函数往往难以获得解析的表达式, 此时需要采用仿真计算或者近似计算的方法来得到高层节点的可靠性特征量。当部件 C_1 至 C_7 之间相互独立时, 系统 S_0 以及子系统 S_1 至 S_3 的可靠度函数可进一步表达成节点 C_1 至 C_7 可靠度函数的函数表达式:

$$\begin{aligned}
 R_{S_0}(t_{S_0}|\boldsymbol{\theta}_{S_0}) &= R_{S_1}(t|\boldsymbol{\theta}_{S_1})R_{S_2}(t|\boldsymbol{\theta}_{S_2})R_{S_3}(t|\boldsymbol{\theta}_{S_3}) \\
 R_{S_1}(t_{S_1}|\boldsymbol{\theta}_{S_1}) &= R_{C_1}(t_{C_1}|\boldsymbol{\theta}_{C_1})R_{C_2}(t_{C_2}|\boldsymbol{\theta}_{C_2}) \\
 R_{S_2}(t_{S_2}|\boldsymbol{\theta}_{S_2}) &= 1 - (1 - R_{C_1}(t_{C_1}|\boldsymbol{\theta}_{C_1}))(1 - R_{C_2}(t_{C_2}|\boldsymbol{\theta}_{C_2})) \\
 R_{S_3}(t_{S_3}|\boldsymbol{\theta}_{S_2}) &= 1 - (1 - R_{C_5}(t_{C_5}|\boldsymbol{\theta}_{C_5})R_{C_6}(t_{C_6}|\boldsymbol{\theta}_{C_6})) \times \\
 &\quad (1 - R_{C_6}(t_{C_6}|\boldsymbol{\theta}_{C_6})R_{C_7}(t_{C_7}|\boldsymbol{\theta}_{C_7}))(1 - R_{C_5}(t_{C_5}|\boldsymbol{\theta}_{C_5})R_{C_7}(t_{C_7}|\boldsymbol{\theta}_{C_7}))
 \end{aligned} \quad (3-3)$$

系统层次结构的可靠性建模方法的实施主要包括以下关键步骤:

- 1) 确定机床系统的研究范围和建模深度。
- 2) 绘制系统的可靠性框图。
- 3) 获得高层节点的可靠性结构函数。

4) 将高层节点的可靠性模型表示为底层节点的函数关系式。

3.3.3 系统多种类型可靠性数据的建模

根据图 3-2 所示的建模框架并结合式(3-2)描述的系统可靠性模型,可知各节点的可靠性模型都描述为时间变量的函数,并且高层节点的可靠性模型最终都描述为底层节点的函数关系式。因此,要对系统中多种类型的可靠性信息进行建模,需要将数据模型与节点的可靠性模型进行关联,为后续基于多源层次信息的模型参数估计与可靠性评估提供信息传递与融合通道。本节首先分别通过对成败型、寿命型与退化型可靠性信息的建模方法进行描述,然后再在此基础上给出多源层次可靠性信息的模型。

(1) 成败型可靠性数据的模型

令 $N^{P/F}$ 表示系统中存在成败型可靠性数据的底层节点 C_j 或者高层节点 S_i , 令 $A^{P/F}$ 表示这些节点的集合。成败型可靠性数据可描述为: 对于节点 $N^{P/F}$ 的成败型数据 $D^{P/F} = (\mathbf{y}^{P/F}, \mathbf{x}^{P/F}, \mathbf{t}^{P/F}) = \{(y_{ij}, x_{ij}, t_{ij}), i=1, \dots, n, j=1, \dots, m_i\}$, 共对 n 组样本进行了观测, 对于第 i 组的节点在观测时间点 t_{ij} , 有 y_{ij} 个节点通过了样本量为 x_{ij} 的成败型测试。令 $Y_{ij}^{P/F}$ 描述 t_{ij} 时刻成败型试验的随机变量, 该随机变量服从如下式所示的二项分布:

$$Y_{ij}^{P/F}(t_{ij} | \boldsymbol{\theta}^{P/F}) \sim \text{Binomial}(y_{ij}; x_{ij}, R(t_{ij} | \boldsymbol{\theta}^{P/F})) \quad (3-4)$$

式中, $R(t_{ij} | \boldsymbol{\theta}^{P/F})$ 为节点在时刻 t_{ij} 的可靠度, 通过这样可以建立节点的可靠度与成败型数据的联系。

因此, 对于节点 $N^{P/F}$ 的成败型数据 $D^{P/F} = (\mathbf{y}^{P/F}, \mathbf{x}^{P/F}, \mathbf{t}^{P/F})$, 根据式(3-4)的模型可以得出数据 $D^{P/F}$ 的似然函数。将数据所包含的信息表述成节点 $N^{P/F}$ 可靠性模型参数的函数表达式:

$$L^{P/F}(\mathbf{y}^{P/F}, \mathbf{x}^{P/F}, \mathbf{t}^{P/F} | \boldsymbol{\theta}^{P/F}) \propto \prod_{i=1}^n \prod_{j=1}^{m_i} \left\{ C_{x_{ij}}^{y_{ij}} \left(R(t_{ij} | \boldsymbol{\theta}^{P/F}) \right)^{y_{ij}} \left(1 - R(t_{ij} | \boldsymbol{\theta}^{P/F}) \right)^{x_{ij} - y_{ij}} \right\} \quad (3-5)$$

其中, $C_{x_{ij}}^{y_{ij}}$ 为从 x_{ij} 中取 y_{ij} 的一个组合数。

(2) 寿命型可靠性数据的模型

令 N^{Life} 表示系统中存在寿命型可靠性数据的底层节点 C_j 或者高层节点 S_i , 令 A^{Life} 表示这些节点的集合。寿命型可靠性数据可描述为: 对于节点 N^{Life} 的寿命数据 $D^{Life} = (\mathbf{t}^L, \mathbf{t}^F, \mathbf{t}^R)$, 共对 n 个样本的寿命进行了观测记录, 其中有 L^L 个节点的寿命时间观测存在左截尾并记录在 $t_{iL}^L, L^L = 1, \dots, L^L$ 中, 有 L^F 个节点观测到了具体的故障时间点并记录在 $t_{iF}^F, L^F = 1, \dots, L^F$ 中, 另外有 L^R 个节点的寿命时间观测存在右截尾

并记录在 $t_{l^R}^R, l^R = 1, \dots, L^R$ 中, 且有 $n = L^L + L^F + L^R$ 。节点 N^{Life} 的可靠度函数和故障概率密度函数分别为 $R(t | \boldsymbol{\theta}^{Life})$ 和 $f(t | \boldsymbol{\theta}^{Life})$ 。对于左截尾时间点 $t_{l^L}^L$ 可将其包含的信息描述为 $1 - R(t_{l^L}^L | \boldsymbol{\theta}^{Life})$, 对于具体的故障时间点 $t_{l^F}^F$ 可将其包含的信息描述为 $f(t_{l^F}^F | \boldsymbol{\theta}^{Life})$, 对于右截尾时间点 $t_{l^R}^R$ 可将其包含的信息描述为 $R(t_{l^R}^R | \boldsymbol{\theta}^{Life})$ 。因此, 节点 N^{Life} 故障时间数据 $D^{Life} = (\mathbf{t}^L, \mathbf{t}^F, \mathbf{t}^R)$ 所包含的可靠性信息可描述为:

$$L^{Life}(\mathbf{t}^L, \mathbf{t}^F, \mathbf{t}^R | \boldsymbol{\theta}^{Life}) = \prod_{l^L=1}^{L^L} (1 - R(t_{l^L}^L | \boldsymbol{\theta}^{Life})) \prod_{l^F=1}^{L^F} f(t_{l^F}^F | \boldsymbol{\theta}^{Life}) \prod_{l^R=1}^{L^R} R(t_{l^R}^R | \boldsymbol{\theta}^{Life}) \quad (3-6)$$

(3) 退化型可靠性数据的模型

令 N^{Deg} 表示系统中存在退化型可靠性数据的底层节点 C_j 或者高层节点 S_i , 令 A^{Deg} 表示这些节点的集合。退化型可靠性数据可描述为: 对于节点 N^{Deg} 的退化数据 $D^{Deg} = (\mathbf{g}^{Deg}, \mathbf{t}^{Deg}) = \{(g_{ij}, t_{ij}), i = 1, \dots, n, j = 1, \dots, m_i\}$, 共对 n 个节点的性能退化数据进行了观测记录, 对于第 i 个节点在观测时间点 t_{ij} , 观测到其对应的性能退化量为 g_{ij} 。本文选用性能退化模型中较为常用的退化轨迹模型来对退化型的可靠性数据建模。令 G^{Deg} 和 Y^{Deg} 分别为描述 N^{Deg} 性能退化观测量 g^{Deg} 和实际退化量 y^{Deg} 的随机变量。每一个时间点 t_{ij} 的性能退化观测量 g_{ij} 由实际的性能退化量 y_{ij} 和观测误差 ξ_i^{Deg} 组成, 且有 $g_{ij} = y_{ij} + \xi_i^{Deg}, \xi_i^{Deg} \sim \text{Normal}(0, \sigma^2)$ 。此时, 节点 N^{Deg} 的性能退化观测数据可以建模为如下形式:

$$G^{Deg}(t_{ij} | \boldsymbol{\beta}^{Deg}, \sigma) \sim \text{Normal}(Y^{Deg}(t_{ij} | \boldsymbol{\beta}^{Deg}), \sigma^2) \quad (3-7)$$

式中, $Y^{Deg}(t_{ij} | \boldsymbol{\beta}^{Deg})$ 为 N^{Deg} 实际性能退化轨迹 (实际退化量), $\boldsymbol{\beta}^{Deg}$ 为对应的模型参数。

在此基础上, 节点 N^{Deg} 性能退化数据 $D^{Deg} = (\mathbf{g}^{Deg}, \mathbf{t}^{Deg})$ 所包含的信息可通过其似然函数描述为:

$$L^{Deg}(\mathbf{g}^{Deg}, \mathbf{t}^{Deg} | \boldsymbol{\theta}^{Deg}) = \prod_{k=1}^K \prod_{l=1}^{l_k} \phi\left(\frac{g_{kl} - Y^{Deg}(t_{kl} | \boldsymbol{\beta}^{Deg})}{\sigma}\right) \quad (3-8)$$

式中, $\phi(\bullet)$ 为标准正态分布的概率密度函数, $\boldsymbol{\theta}^{Deg} = \{\boldsymbol{\beta}^{Deg}, \sigma\}$ 为性能退化数据的模型参数。

对于具有性能退化的节点 N^{Deg} , 在工程中往往对其故障作如下的判定: 当其实际性能退化量超出了给定的故障阈值 Y^D 时, N^{Deg} 即被判为发生了故障。此时, 基于 N^{Deg} 实际性能退化轨迹的模型 $Y^{Deg}(t_{kl} | \boldsymbol{\beta}^{Deg})$, 即可建立式(3-8)所示的性能退化数据包含的信息与 N^{Deg} 可靠性之间的关系如下:

$$R(t | \boldsymbol{\beta}^{Deg}) = \Pr\{Y^{Deg}(t | \boldsymbol{\beta}^{Deg}) \geq Y^D\} \quad (3-9)$$

值得指出的是性能退化数据的建模往往根据实际情况存在多种不同的模型，但建模的基本过程多与上述过程相似。建模的关键在于：首先通过性能退化数据的似然函数，将性能退化数据所包含的信息表述成模型参数的量化形式，然后将退化模型的模型参数与节点的可靠性模型进行相互关联。

当所有类型可靠性数据的信息都得到表达，并与对应节点的可靠性模型建立起关系之后，即可在此基础上构建多源层次信息的模型如下：

$$L(D^{P/F}, D^{Life}, D^{Deg} | \Theta) = \prod_{N_k^{P/F} \in A^{P/F}} L_k^{P/F}(\mathbf{y}_k^{P/F}, \mathbf{x}_k^{P/F}, \mathbf{t}_k^{P/F} | \theta_k^{P/F}) \times \prod_{N_k^{Life} \in A^{Life}} L_k^{Life}(\mathbf{t}_k^L, \mathbf{t}_k^F, \mathbf{t}_k^R | \theta_k^{Life}) \times \prod_{N_k^{Deg} \in A^{Deg}} L_k^{Deg}(\mathbf{g}_k^{Deg}, \mathbf{t}_k^{Deg} | \theta_k^{Deg}) \quad (3-10)$$

式中， Θ 包含了所有可靠性数据模型的参数，根据故障数据模型与可靠性模型之间的关系可知系统可靠性模型的所有参数 θ_{S_0} 为 Θ 的子集。

式(3-10)中对应数据类型似然函数的获取，可根据数据类型的不同依照式(3-5)、(3-6)和(3-8)所构建的方法来构建。当数据对应的节点为底层节点时，可将底层节点的可靠性模型或者参数的函数表达式代入式(3-5)、(3-6)和(3-8)来得到对应数据的似然函数。当数据对应的节点为高层节点时，需要利用式(3-1)来获取高层节点的可靠性模型，然后将其代入到式(3-5)和(3-6)来得到对应数据的似然函数。

下面以图 3-1 所示的系统模型和对应的可靠性数据为例，来对上述建模过程进行示例性演示。对于具有成败型数据的 C_1 、 C_2 和 C_5 ，采用指数分布来对其可靠性进行建模，有 $T_i \sim \text{Exponential}(\lambda_i)$ ， $i=1,2,5$ 。对于具有寿命型数据的 C_3 和 C_4 ，采用双变量威布尔分布来对其进行建模，有 $(T_3, T_4) \sim \text{MOBW}(\alpha_{34}, \lambda_{34a}, \lambda_{34b}, \lambda_{34c})$ ，以描述两者之间存在关联关系的情形，其联合分布函数如下式所示：

$$F(t_3, t_4) = 1 - \exp\left(-\left(\lambda_{34a} t_3^{\alpha_{34}} + \lambda_{34b} t_4^{\alpha_{34}} + \lambda_{34c} \max(t_3^{\alpha_{34}}, t_4^{\alpha_{34}})\right)\right) \quad (3-11)$$

与此同时，对于具有寿命型数据的 C_6 ，采用威布尔分布来对其进行建模，有 $T_6 \sim \text{Weibull}(\beta_6, \eta_6)$ 。对于具有性能退化型数据的 C_7 ，采用线性退化轨迹模型来对其进行建模，有 $Y^{Deg}(t_{ij} | \gamma^{Deg}) = \alpha_7 - t_{ij} \gamma_i^{-1}$ 且用 $\gamma_i \sim \text{Weibull}(\beta_7, \eta_7)$ 来描述样本之间的差异性，此时 C_7 的可靠性模型可描述成 $T_7 \sim \text{Weibull}(\beta_7, \eta_7(\alpha_7 - Y_7^D))$ 。根据式(3-3)所描述的高层次的可靠性模型与底层节点可靠性模型的关系，可以得到此时系统 S_0 以及子系统 S_1 、 S_2 至 S_3 的可靠度函数如下：

$$\begin{aligned}
 R_{S_0}(t | \boldsymbol{\theta}_{S_0}) &= R_{S_1}(t) R_{S_2}(t) R_{S_3}(t) = R_1(t) R_2(t) \times R_{34}(t) \times \\
 &\quad (R_5(t) R_6(t) + R_5(t) R_7(t) + R_6(t) R_7(t) - 2R_5(t) R_6(t) R_7(t)); \\
 R_{S_1}(t | \boldsymbol{\theta}_{S_1}) &= \exp(-(\lambda_1 + \lambda_2)t); \\
 R_{S_2}(t | \boldsymbol{\theta}_{S_2}) &= \exp(-(\lambda_{34a} + \lambda_{34c})t^{\alpha_{34}}) + \exp(-(\lambda_{34b} + \lambda_{34c})t^{\alpha_{34}}) - \\
 &\quad \exp(-(\lambda_{34a} + \lambda_{34b} + \lambda_{34c})t^{\alpha_{34}}); \\
 R_{S_3}(t | \boldsymbol{\theta}_{S_3}) &= \exp(-\lambda_5 t - (t/\eta_6)^{\beta_6}) + \exp(-\lambda_5 t - (t/(\eta_7(\alpha_7 - Y_7^D)))^{\beta_7}) + \\
 &\quad \exp(- (t/\eta_6)^{\beta_6} - (t/(\eta_7(\alpha_7 - Y_7^D)))^{\beta_7}) - \\
 &\quad 2 \times \exp(-\lambda_5 t - (t/\eta_6)^{\beta_6} - (t/(\eta_7(\alpha_7 - Y_7^D)))^{\beta_7})
 \end{aligned} \tag{3-12}$$

式中，系统 S_0 的模型参数 $\boldsymbol{\theta}_{S_0} = (\boldsymbol{\theta}_{S_1}, \boldsymbol{\theta}_{S_2}, \boldsymbol{\theta}_{S_3})$ ，其包含了子系统 S_1 、 S_2 和 S_3 的模型参数 $\boldsymbol{\theta}_{S_1} = (\lambda_1, \lambda_2)$ ， $\boldsymbol{\theta}_{S_2} = (\alpha_{34}, \lambda_{34a}, \lambda_{34b}, \lambda_{34c})$ 和 $\boldsymbol{\theta}_{S_3} = (\lambda_5, \beta_6, \eta_6, \alpha_7, \beta_7, \eta_7)$ 。

在此基础上，将式(3-12)所示的高层节点的可靠性模型代入到式(3-6)所示的寿命型数据的可靠性模型中，即可获得图 3-1 所示的多源层次可靠性数据的模型如下：

$$\begin{aligned}
 L(D^{P/F}, D^{Life}, D^{Deg} | \boldsymbol{\Theta}) &= L_{C_1}^{P/F}(\mathbf{y}_{C_1}^{P/F}, \mathbf{x}_{C_1}^{P/F}, \mathbf{t}_{C_1}^{P/F} | \lambda_1) L_{C_2}^{P/F}(\mathbf{y}_{C_2}^{P/F}, \mathbf{x}_{C_2}^{P/F}, \mathbf{t}_{C_2}^{P/F} | \lambda_2) \times \\
 &\quad L_{C_3, C_4}^{Life}(\mathbf{t}_{C_3, C_4}^L, \mathbf{t}_{C_3, C_4}^F, \mathbf{t}_{C_3, C_4}^R | \alpha_{34}, \lambda_{34a}, \lambda_{34b}, \lambda_{34c}) L_{C_5}^{P/F}(\mathbf{y}_{C_5}^{P/F}, \mathbf{x}_{C_5}^{P/F}, \mathbf{t}_{C_5}^{P/F} | \lambda_5) \times \\
 &\quad L_{C_6}^{Life}(\mathbf{t}_{C_6}^L, \mathbf{t}_{C_6}^F, \mathbf{t}_{C_6}^R | \beta_6, \eta_6) L_{C_7}^{Deg}(\mathbf{g}_{C_7}^{Deg}, \mathbf{t}_{C_7}^{Deg} | \alpha_7, \beta_7, \eta_7, \sigma_7) \times \\
 &\quad L_{S_1}^{P/F}(\mathbf{t}_{S_1}^L, \mathbf{t}_{S_1}^F, \mathbf{t}_{S_1}^C | \boldsymbol{\theta}_{S_1}) L_{S_2}^{Life}(\mathbf{t}_{S_2}^L, \mathbf{t}_{S_2}^F, \mathbf{t}_{S_2}^C | \boldsymbol{\theta}_{S_2}) \times \\
 &\quad L_{S_3}^{Life}(\mathbf{t}_{S_3}^L, \mathbf{t}_{S_3}^F, \mathbf{t}_{S_3}^R | \boldsymbol{\theta}_{S_3}) \times \\
 &\quad L_{S_0}^{Life}(\mathbf{t}_{S_0}^L, \mathbf{t}_{S_0}^F, \mathbf{t}_{S_0}^R | \boldsymbol{\theta}_{S_0})
 \end{aligned} \tag{3-13}$$

系统多种类型的可靠性信息建模方法的实施主要包括以下关键步骤：

- 1) 确定机床系统的多层次客观数据集。
- 2) 分析各层次节点的可靠性特性以及对应客观数据的特性。
- 3) 建立各底层节点客观数据的模型并与可靠性模型相关联。
- 4) 建立高层节点客观数据的模型并与可靠性模型相关联。
- 5) 建立多源层次客观数据的模型。

3.4 基于混合贝叶斯网络的重型数控机床可靠性评估

上文所构建的机床可靠性建模框架及相应的建模方法，为机床多源层次信息

的融合与机床可靠性的评估提供了核心基础。系统不同层次节点的可靠性模型已经通过底层节点对应的模型参数进行了关联，同时系统中多种类型客观信息的数据模型也构建在节点可靠性模型参数之上，这些都为信息的传递与融合提供了基本的通道，也为系统中各节点可靠性指标的评估提供了基本途径。在此基础上，为了实现基于多源层次信息集的可靠性评估，需要着重解决以下两方面的问题：多层次主客观信息的融合问题以及基于多源层次信息的可靠性评估实现问题。本文将研究构建基于贝叶斯网络的多源层次信息融合评估方法，来解决这两个关键问题。

3.4.1 基于贝叶斯网络的多源层次信息融合基本框架

贝叶斯网络理论起源于 20 世纪 80 年代对人工智能领域不确定性推理问题的研究，由 Judea Pearl 教授于 1988 年提出^[128]。贝叶斯网络作为图论与概率论完美结合的产物：一方面利用图论的图形化语言，来对问题的结构进行直观描述；另一方面根据概率论的基本方法，来对不确定性推理问题的求解进行高效处理^[129]。由于贝叶斯网络具有直观易懂的建模能力和综合全面的推理能力，近年来在可靠性工程领域特别在针对复杂系统的建模^[131-132]、分析^[133-134]与评估^[134]中得到了广泛的研究与应用^[136-137]。

下面从系统可靠性建模与评估的角度进一步对贝叶斯网络进行介绍。

以图 3-1 所示系统中的子系统 S_1 为例，其对应的贝叶斯网络如图 3-3 所示。直观来说，完整的贝叶斯网络包括定性和定量两个部分。定性部分是指由节点和有向边构成的有向无环图，其中节点代表随机变量而有向边则代表随机变量之间的直接关联关系，有向无环图则描述了所有随机变量之间的依赖与独立关系。定量部分是指节点附有的概率分布，对于有向无环图中的根节点所附的是该节点的边缘概率分布，而对于非根节点所附的是该节点基于其父节点的条件概率分布。

图 3-3 所示贝叶斯网络的定性部分由子系统节点 S_1 、部件节点 C_1 和 C_2 、部件节点对应的模型参数节点 λ_1 和 λ_2 以及节点之间的有向边构成。子系统节点和部件节点分别代表 S_1 、 C_1 和 C_2 的可靠性对应的随机变量，如各节点对应的寿命 T_{S_1} 、 T_{C_1} 和 T_{C_2} 。模型参数节点分别代表未知参数 λ_1 和 λ_2 对应的随机变量。由 C_1 和 C_2 指向 S_1 的有向边表示节点 S_1 的寿命分布（可靠度函数）依赖于 C_1 和 C_2 的寿命分布（可靠度函数），且 C_1 和 C_2 称为 S_1 的父节点。同理，由 λ_1 指向 C_1 和 λ_2 指向 C_2 的有向边表示节点 C_1 和 C_2 的寿命分布（可靠度函数）分别依赖于模型参数 λ_1 和 λ_2 的概率分布，且有 λ_1 为 C_1 的父节点以及 λ_2 为 C_2 的父节点。

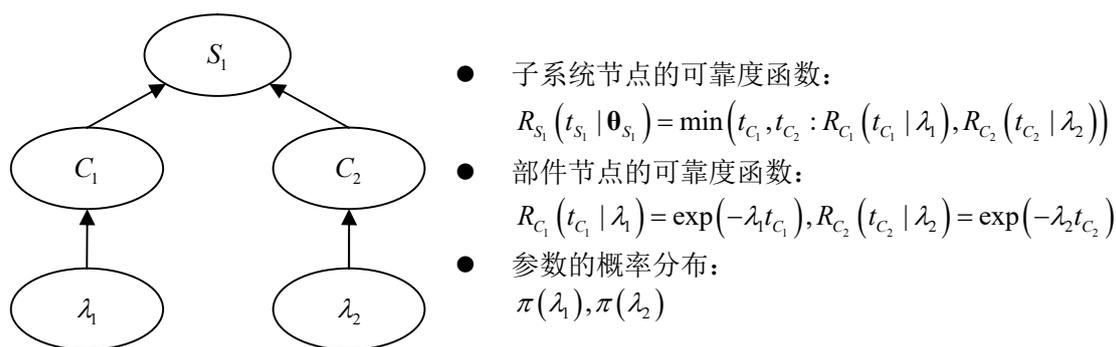


图 3-3 贝叶斯网络示例

图 3-3 所示贝叶斯网络的定量部分由子系统节点的可靠度函数 $R_{S_1}(t_{S_1} | \theta_{S_1})$ 、部件节点的可靠度函数 $R_{C_1}(t_{C_1} | \lambda_1)$ 和 $R_{C_2}(t_{C_2} | \lambda_2)$ 以及参数的先验分布 $\pi(\lambda_1)$ 和 $\pi(\lambda_2)$ 组成。模型参数节点 λ_1 和 λ_2 为根节点，其对应的概率分布为边缘概率分布。子系统节点 S_1 、部件节点 C_1 和 C_2 为非根节点，其对应的概率分布为基于各自父节点的条件概率分布。

在以上对贝叶斯网络在可靠性领域的直观描述的基础上，本文将进一步探索基于贝叶斯网络的可靠性建模与评估方法。一方面研究利用贝叶斯网络的定性部分直观地建立复杂系统多层次节点之间、节点与模型参数之间以及节点与影响因素之间的关系；另一方面研究利用贝叶斯网络的定量部分高效地实现主客观信息的融合、多层次可靠性数据的融合以及系统可靠性的评估。据此本文研究构建了基于贝叶斯网络的多源层次信息融合基本框架如图 3-4 所示。

本文构建的多源层次信息融合基本框架主要包括基于贝叶斯网络的系统建模以及基于贝叶斯网络的信息融合与评估两大部分。

(1) 基于贝叶斯网络的系统建模是通过将上文所建立的系统中各层次节点的可靠性模型映射为贝叶斯网络中的节点与有向边，然后利用贝叶斯网络的定性部分来直观地建立复杂系统多层次节点以及节点与模型参数间的关联关系，为基于贝叶斯网络的多源层次信息融合提供基础。

(2) 基于贝叶斯网络的信息融合与评估是通过将上文所构建的多层客观数据集的模型嵌入贝叶斯网络的定量部分中，并在此基础上进一步研究主客观信息集的贝叶斯网络融合方法；然后利用层次贝叶斯方法对多层客观数据的融合能力以及贝叶斯网络对不确定推理的运算能力，来实现基于贝叶斯网络的多源层次信息融合与系统可靠性评估。

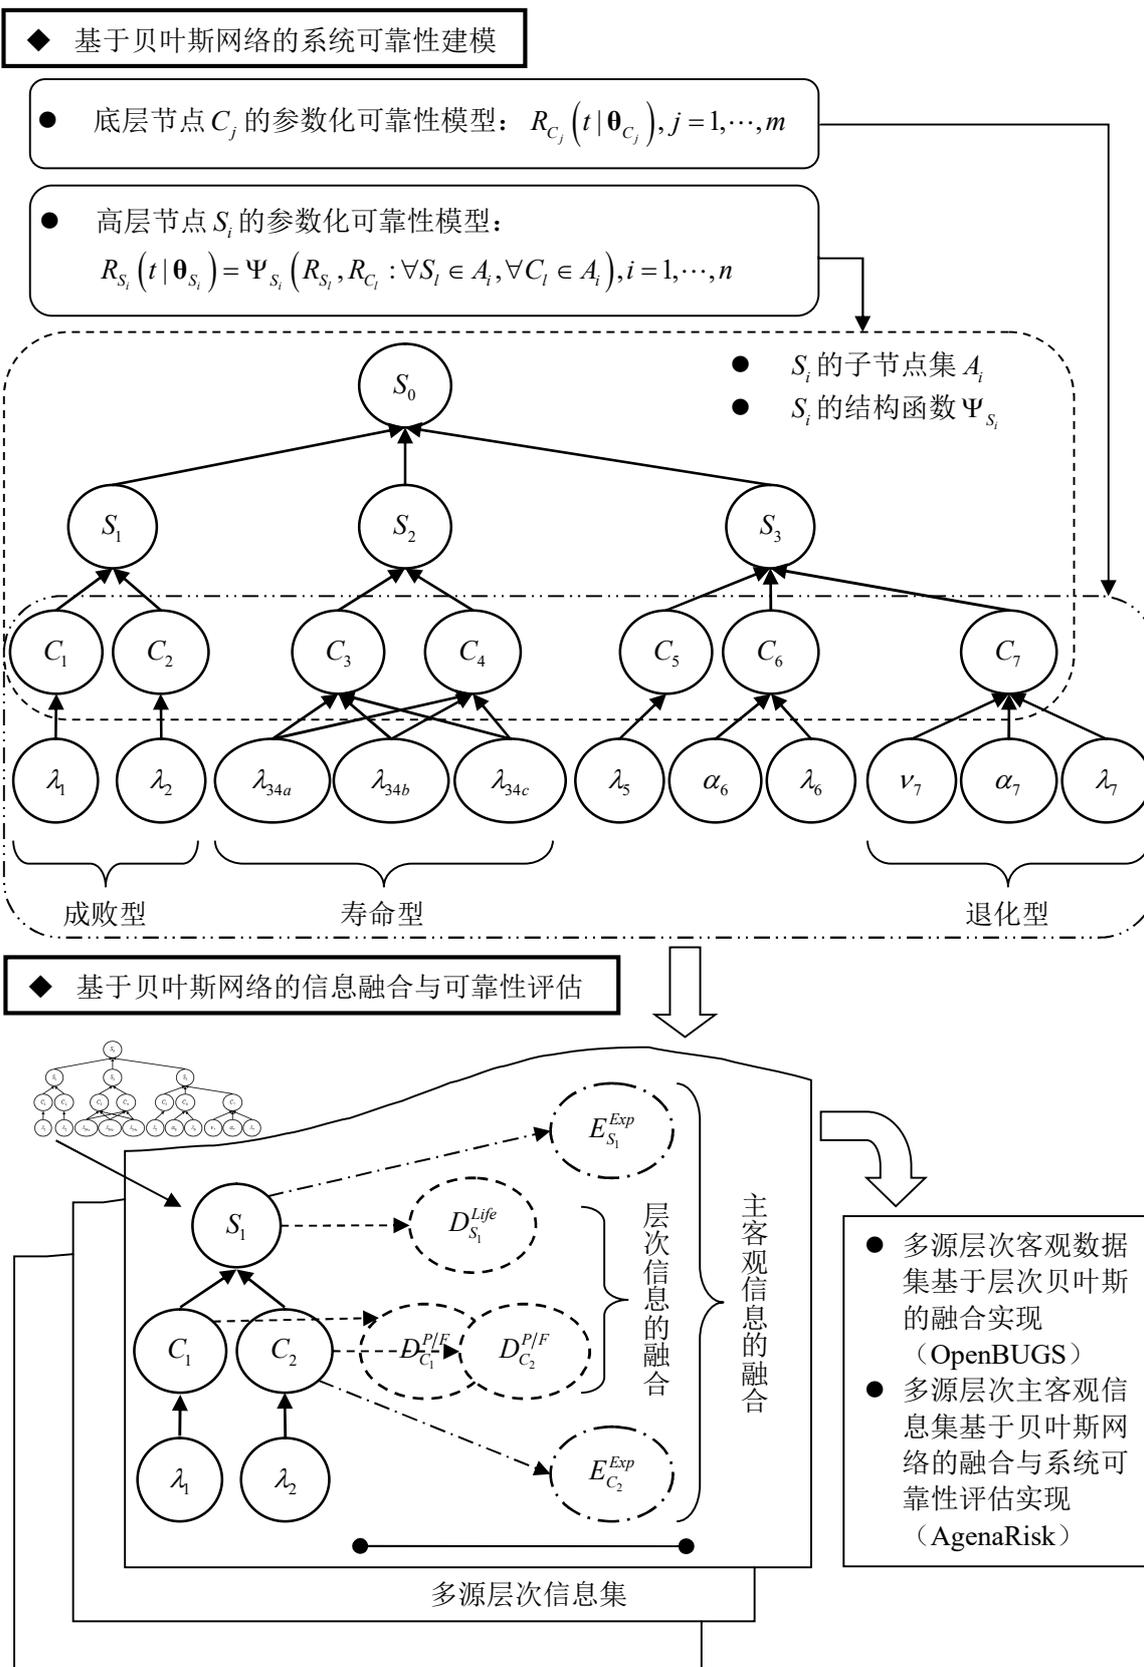


图 3-4 基于贝叶斯网络的多源层次信息融合基本框架

3.4.2 多源层次信息的贝叶斯网络模型表达

多源层次信息的贝叶斯网络模型是将本章 3.3 中所建立的模型用贝叶斯网络模型进行描述，其主要包括层次系统结构的贝叶斯网络模型以及成败型、寿命型和退化型可靠性数据对应的贝叶斯网络模型。下面根据图 3-4 所示的基于贝叶斯网络的系统可靠性建模的基本思路，逐步给出多源层次信息的贝叶斯网络模型。

(1) 层次系统结构的贝叶斯网络模型

系统贝叶斯网络模型的构建是将式(3-1)所描述的系统可靠性关系用贝叶斯网络直观的描述出来，同时为基于贝叶斯网络的多源信息融合提供基本的系统贝叶斯网络模型。系统可靠性模型的构建是以系统中各节点的可靠度函数为关联关系，并且可靠度函数本质上与节点寿命的随机变量相关联（时间相关的随机变量）；因此，在系统贝叶斯网络模型的构建中，可将系统中各节点对应的寿命（时间相关的随机变量）作为贝叶斯网络模型中的节点来进行表示。在此基础上，将各节点对应的可靠度函数作为贝叶斯网络模型中节点所附的概率分布，以此来构建系统的贝叶斯网络模型。根据这样的模型转换和系统贝叶斯网络模型构建的思路，图 3-7 给出了式(3-1)所对应的底层节点和高层节点一般化贝叶斯网络模型。

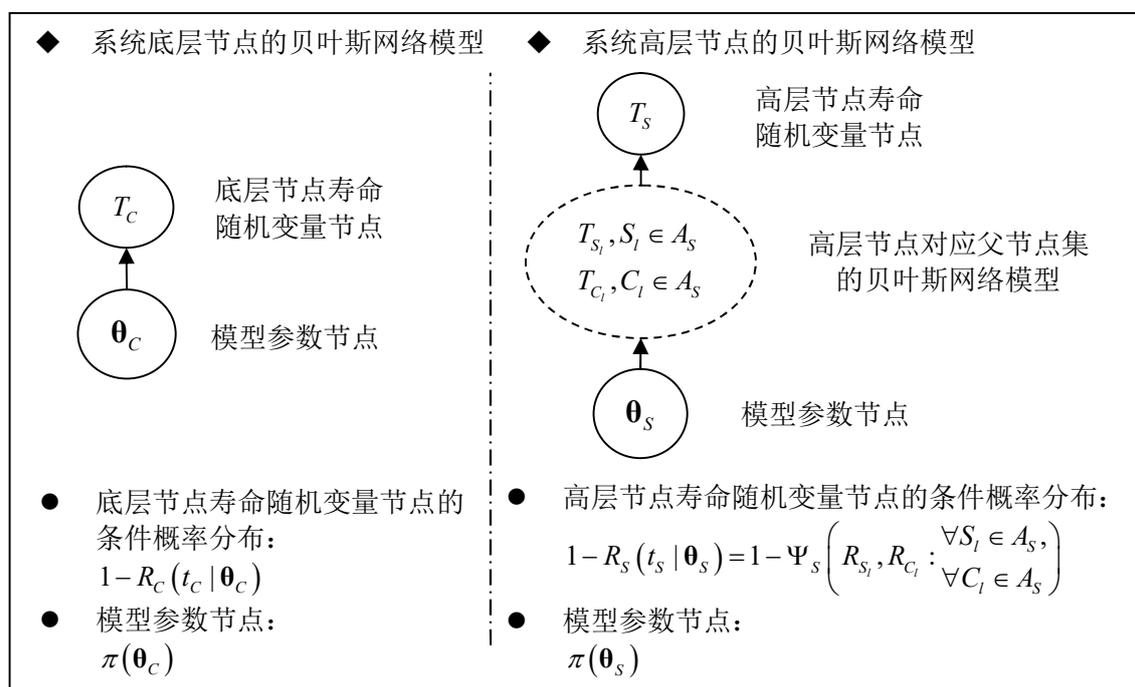


图 3-5 层次系统中底层节点和高层节点的贝叶斯网络模型

图 3-5 中底层节点的贝叶斯网络模型较为直观，当节点的寿命分布和模型参数的边缘概率分布得到确定之后，对应节点的贝叶斯网络模型也得到了确定。对于高层节点的贝叶斯网络模型，则需要借助于该高层节点对应父节点的贝叶斯网络

来进行确定。此时需要逐步建立其父节点的贝叶斯网络模型，来最终得到高层节点的贝叶斯网络模型。典型的高层节点的贝叶斯网络模型示例如图 3-3 所示。对于图 3-1 所示的系统，当选用式(3-12)中对应节点的可靠性模型时，该系统的层次可靠性模型如图 3-6 所示，其中 $T_N, N = S_0, \dots, C_7$ 为系统中节点对应寿命的随机变量。

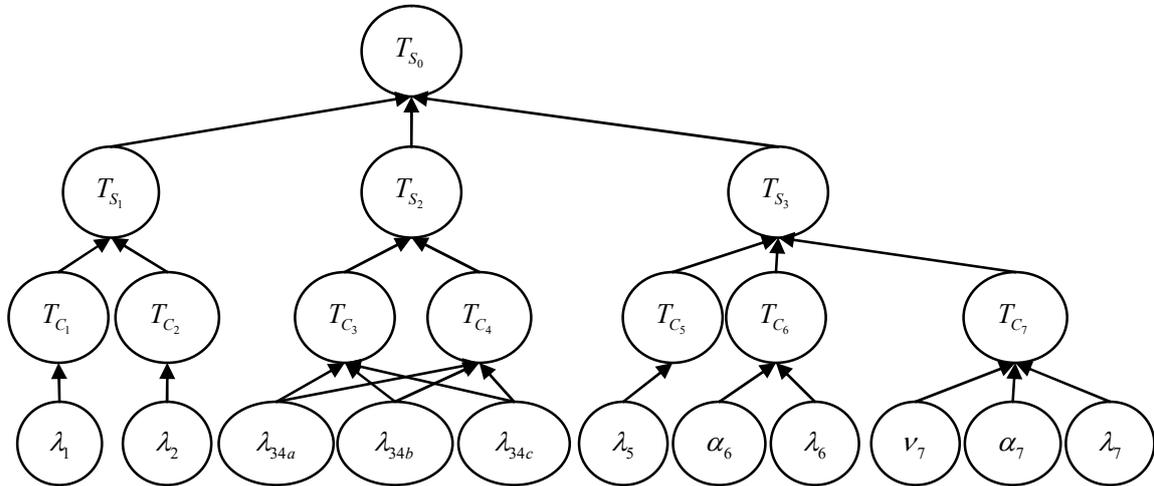


图 3-6 层次贝叶斯网络模型示例

(2) 成败型数据对应系统节点的贝叶斯网络模型

根据式(3-4)所建立的成败型数据的模型，首先给出成败型数据对应底层节点的贝叶斯网络模型如图 3-7 所示。贝叶斯网络的定性部分如图 3-7 左侧所示，系统底层节点的可靠度节点、模型参数节点、成败型数据节点之间的关系都得到了明确的描述。贝叶斯网络的定量部分如图 3-7 右侧所示，参数节点与可靠度节点所附的概率分布为连续型概率分布，且参数节点对应为边缘分布而可靠度节点对应为条件概率分布；成败型数据节点所附的概率分布为离散型概率分布且为条件概率分布。在定量部分确定时，对于观测到的一组成败型数据 $(y_c^{P/F}, x_c^{P/F}, t_c^{P/F})$ ，分别通过节点 $Y_c^{P/F}$ 和节点 R_c 来引入，其中 $t_c^{P/F}$ 和 $x_c^{P/F}$ 是分别通过节点 R_c 和节点 $Y_c^{P/F}$ 的条件概率分布来引入的，而 $y_c^{P/F}$ 则是通过节点 $Y_c^{P/F}$ 的节点证据输入来引入的（二项分布随机变量的样本观测值输入）。对于成败型数据集 $D^{P/F} = (y^{P/F}, x^{P/F}, t^{P/F})$ ，当其包含了多组 $(y_c^{P/F}, x_c^{P/F}, t_c^{P/F})$ 时，需要以模型参数节点 $\theta_c^{P/F}$ 为同一父节点，针对每一组数据构建图 3-7 所示的贝叶斯网络来对其进行建模引入，从而实现所有数据与其共同的模型参数相关联。

成败型数据对应高层节点的贝叶斯网络模型如图 3-8 所示。贝叶斯网络的定性部分如图 3-8 左侧所示，与底层节点的贝叶斯网络不同，在高层节点的贝叶斯网络中可靠度节点与模型参数节点之间需要通过高层节点对应父节点集的贝叶斯网络来进行连接。高层节点与成败型数据节点之间的关系可以明确从贝叶斯网络中体

现，而高层节点与参数节点的关系则需要通过系统贝叶斯网络模型来得到体现。模型节点 $\theta_s^{P/F}$ 包含了所有与高层节点可靠性模型相关的所有底层节点的模型参数。贝叶斯网络的定量部分如图 3-8 右侧所示，参数节点与可靠度节点所附的概率分布为连续型概率分布，且参数节点对应为边缘分布而可靠度节点对应为条件概率分布；成败型数据节点所附的概率分布为离散型概率分布且为条件概率分布。此外，高层节点对应父节点集的贝叶斯网络模型中，节点的概率分布都为连续型寿命分布且都为条件概率分布。数据观测点 $(y_s^{P/F}, x_s^{P/F}, t_s^{P/F})$ 的引入与底层节点类似，都是通过节点 $Y_s^{P/F}$ 和 R_s 来引入的。当 $D^{P/F} = (y^{P/F}, x^{P/F}, t^{P/F})$ 包含了多组 $(y_s^{P/F}, x_s^{P/F}, t_s^{P/F})$ 时，同样也需要以参数节点 $\theta_s^{P/F}$ 为同一父节点，针对每一组数据构建图 3-8 所示的贝叶斯网络，来将所有数据与其共同的模型参数进行关联。

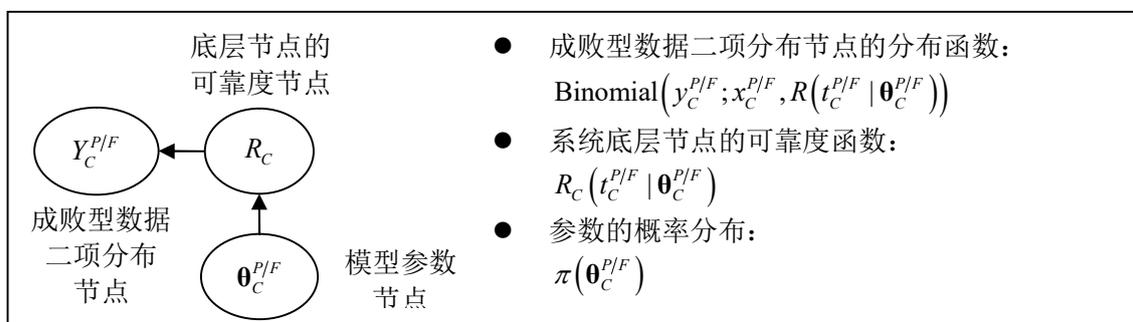


图 3-7 成败型数据对应底层节点的贝叶斯网络模型

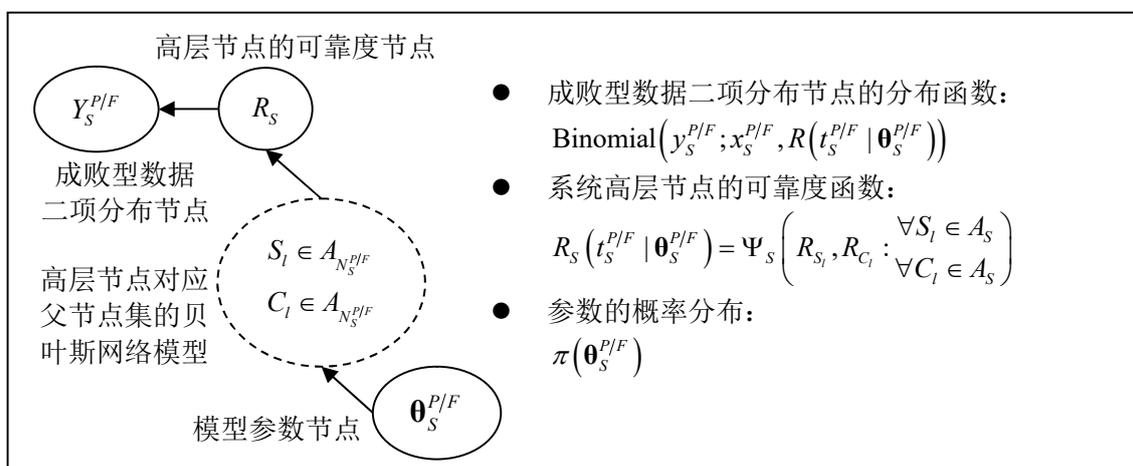


图 3-8 成败型数据对应高层节点的贝叶斯网络模型

(3) 寿命型数据对应系统节点的贝叶斯网络模型

寿命数据本质上是对应节点寿命随机变量（时间相关的随机变量）的样本。因此，只需要将寿命数据的观测值进行引入到图 3-5 所示的贝叶斯网络模型中，即可完成贝叶斯网络模型的构建。由于寿命数据中存在截尾的情形，往往难以直接

进行寿命数据的引入。本文在图 3-5 所示的贝叶斯网络模型的基础上，通过引入寿命数据节点来建立寿命型数据对应节点的贝叶斯网络模型，所建立的贝叶斯网络模型如图 3-9 所示。

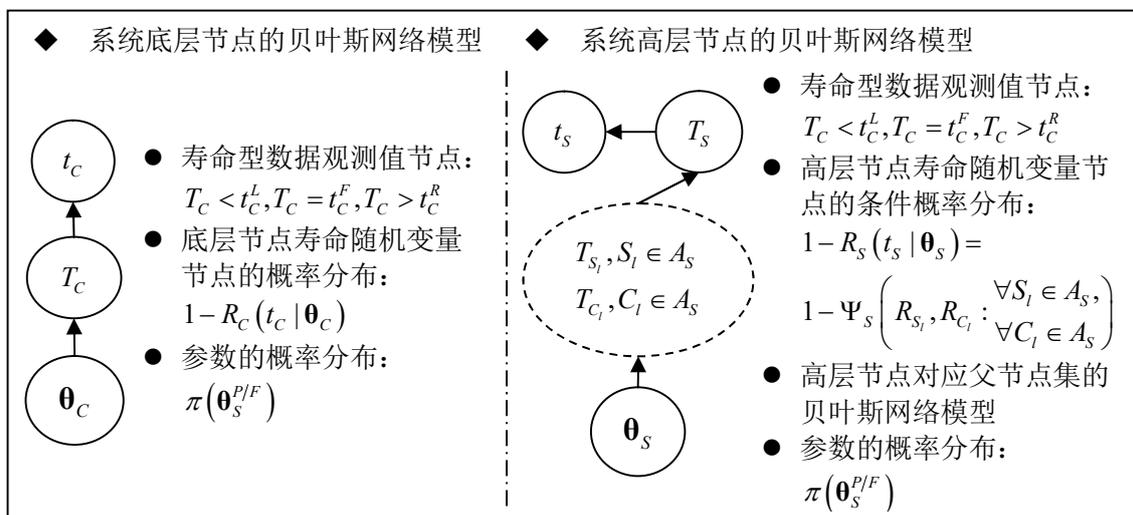


图 3-9 寿命型数据对应节点的贝叶斯网络模型

图中寿命型数据观测值节点是对寿命数据的描述，根据寿命数据截尾形式的不同，如左截尾数据 t^L 、右截尾数据 t^R 或故障数据 t^F ，该节点的量化部分可分别描述为 $T_C < t_C^L$ 、 $T_C > t_C^R$ 或 $T_C = t_C^F$ 及其对应的“是”与“否”的选择点。当观测到寿命数据时，则可将观测值节点相应证据输入设定为“是”，从而实现观测数据的引入。如图 3-8 所示系统底层节点与高层节点对应的贝叶斯网络模型的区别在于：高层节点的贝叶斯网络中寿命随机变量节点与模型参数节点之间，需要通过高层节点对应父节点集的贝叶斯网络模型来进行连接。

(4) 退化型数据对应系统节点的贝叶斯网络模型

根据式(3-7)所建立的退化型数据的模型，可以构建退化型数据对应底层节点的贝叶斯网络模型如图 3-10 所示。

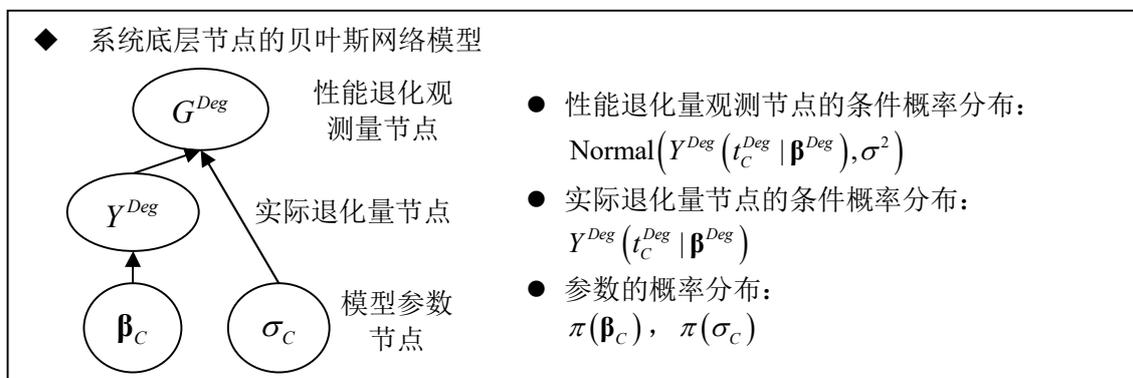


图 3-10 退化型数据对应节点的贝叶斯网络模型

该贝叶斯网络的定性部分描述了性能退化观测节点、实际退化量节点以及模型参数节点之间的关系。定量部分主要包括了观测节点的条件概率分布、实际退化量节点的条件概率分布以及模型参数节点的边缘概率分布。退化数据观测点 (g_C^{Deg}, t_C^{Deg}) 的引入是通过节点 G^{Deg} 和节点 Y^{Deg} 来实现的，其中 g_C^{Deg} 是通过节点 G^{Deg} 的节点证据输入来引入的（正态分布随机变量的样本观测值输入）， t_C^{Deg} 则是通过节点 Y^{Deg} 的条件概率分布的确定来引入的。

(5) 独立来源的层次客观数据的贝叶斯网络模型

在成败型、寿命型和退化型数据对应系统节点的贝叶斯网络模型的基础上，根据图 3-4 所示的多源层次信息融合的基本框架，可以构建独立来源的层次客观数据的贝叶斯网络模型如图 3-11 所示。

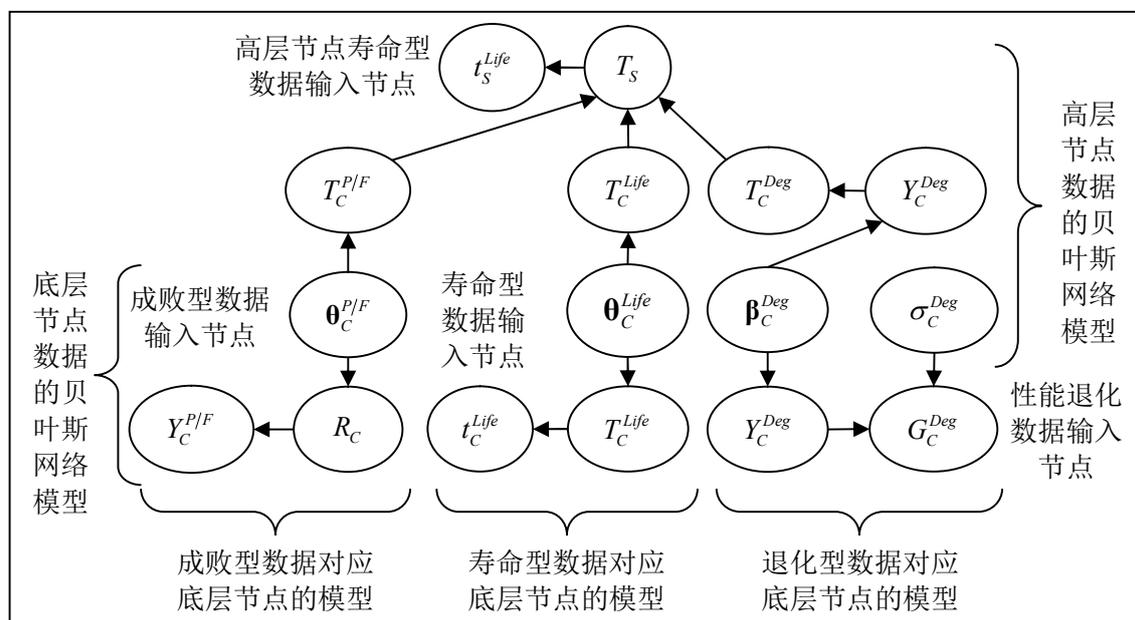


图 3-11 独立来源的层次客观数据的贝叶斯网络模型

该贝叶斯网络是融合独立来源的成败型、寿命型和退化型数据的一般化贝叶斯网络。贝叶斯网络的定性部分描述了底层节点的可靠性数据、高层节点的可靠性数据以及系统模型参数之间的关系。系统节点独立来源的层次可靠性数据所包含的信息最终都通过系统的模型参数来进行表达。如图 3-11 所示所示，该贝叶斯网络模型中模型参数节点为层次可靠性数据所共有，不同数据输入节点都通过各自的贝叶斯网络与模型参数建立关联，这使得层次数据中各数据来源的相互独立性得以体现。贝叶斯网络的定量部分可以参见上文成败型、寿命型和退化型数据对应贝叶斯网络的定量描述。系统底层节点成败型、寿命型和退化型数据的输入分别是通过 $Y_C^{P/F}$ 、 t_C^{Life} 、 G_C^{Deg} 和 Y_C^{Deg} 来完成的，系统高层节点寿命型数据则是通过

t_s^{Life} 来完成的。

(6) 主观信息的贝叶斯网络模型

根据 3.2 节中多源层次信息集的特性分析,可知重型数控机床中存在的主观信息主要包括:设计研制人员的专家经验信息以及机床使用和维修人员的经验信息。这两种主观信息主要以主观评价的形式表达为对机床整机或关键子系统可靠性的专家意见和评价。考虑到机床的可靠性模型都是在寿命随机变量(时间相关的随机变量)之上的,因此本文将着重研究针对寿命随机变量的主观信息的量化、建模与融合,本文所采用寿命相关的指标为机床的 MTBF 和可靠度。

首先采用概率编码的方法来对主观信息进行收集和量化。针对机床的 MTBF 或者某一时间点机床的可靠度设置相应的概率赋值问题,然后根据专家对这些指标的概率赋值,求得 MTBF 的概率分布或者某一时间点可靠度的值。关于概率赋值问题和专家赋值方式的设定,可以参见 O'Hagan 的系列著作^[137]以及专家主观概率量化方面的研究成果^[139-142]。本文概率编码方法主要涵盖以下关键步骤:

- 1) 选择机床寿命随机变量对应的指标参数。
- 2) 选择指标参数的概率赋值方法类型,并制订合适的概率赋值问题。
- 3) 选择组织专家,对指标参数进行概率赋值。
- 4) 根据概率赋值获得指标参数的连续概率分布或者离散概率分布。

当采用以上的概率编码方法对主观信息进行量化后,得到 MTBF 的概率分布为 $\pi(\text{MTBF}^{Exp})$ 以及某一时间点 t^{Exp} 的可靠度为 $R^{Exp}(t^{Exp})$ 。为了将量化后的主观信息与系统模型参数相关联,可以建立如图 3-12 所示的贝叶斯网络。

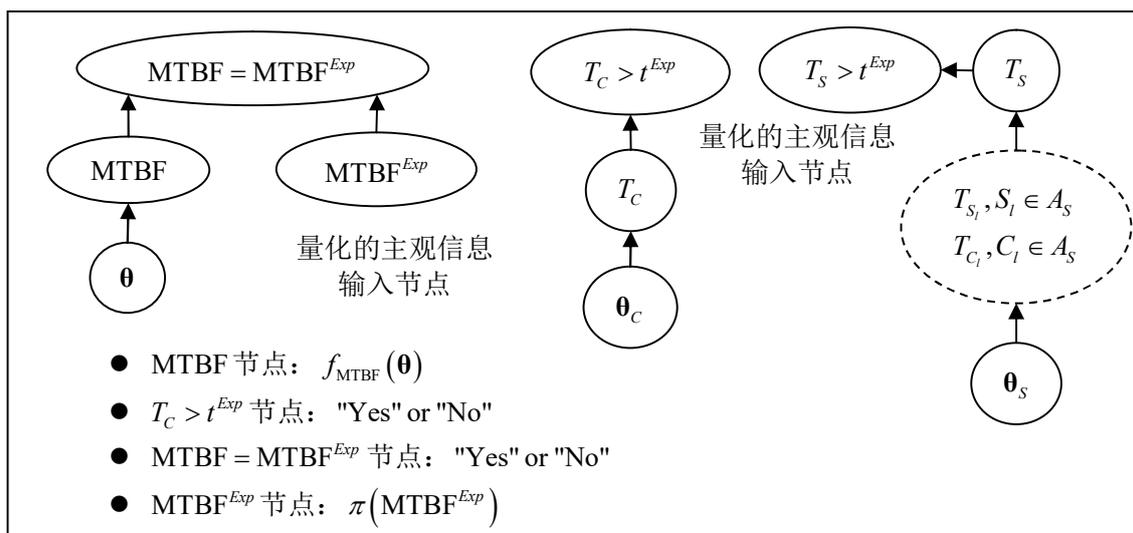


图 3-12 主观信息的贝叶斯网络模型

图中包含了关于系统底层节点和高层节点 MTBF 主观信息和可靠度 $R^{Exp}(t^{Exp})$

主观信息输入的贝叶斯网络模型。MTBF 主观信息的贝叶斯网络模型是建立在节点 MTBF 与模型参数 θ 的函数关系 $f_{\text{MTBF}}(\theta)$ 已知的条件下的。MTBF 主观信息的输入需要借助于 $\text{MTBF} = \text{MTBF}^{\text{Exp}}$ 证据输入节点的设定：当该节点的取值设定为“**Yes**”时，节点 MTBF^{Exp} 与 MTBF 之间建立了关联， MTBF^{Exp} 所包含的信息可以通过 MTBF 节点输入到模型参数中。可靠度 $R^{\text{Exp}}(t^{\text{Exp}})$ 主观信息的贝叶斯网络是建立在如图 3-5 所示的节点寿命随机变量的贝叶斯网络模型基础上的。 $R^{\text{Exp}}(t^{\text{Exp}})$ 主观信息的输入需要借助于 $T > t^{\text{Exp}}$ 节点的“软”证据输入来确定：节点 $T > t^{\text{Exp}}$ 的输入为 $\text{Pr}(\text{"Yes"}) = R^{\text{Exp}}(t^{\text{Exp}})$ 和 $\text{Pr}(\text{"No"}) = 1 - R^{\text{Exp}}(t^{\text{Exp}})$ ，这样使得 $R^{\text{Exp}}(t^{\text{Exp}})$ 所包含的信息通过 T_s 相关的贝叶斯网络输入到模型参数中。

3.4.3 多源层次信息的融合与系统可靠性评估

在层次系统的可靠性模型以及多源层次信息的贝叶斯网络模型的基础上，如何实现多源层次信息的融合以及系统可靠性的评估成为基于多源层次信息集的机床可靠性评估的关键所在。由 3.4.2 节中所构建的独立来源的层次客观数据集的贝叶斯网络可知，要融合多组层次客观数据需要在共同的模型参数节点上建立每一组数据的贝叶斯网络模型。此时，用于多源层次客观数据融合的贝叶斯网络将会出现节点较多、求解计算难度较大的问题。因此，可以考虑将多源层次信息集分为两大部分：独立来源的层次客观数据集和关联来源的层次主客观信息集。对于独立来源的层次客观数据集，可以应用层次贝叶斯方法来对数据进行融合得到模型参数的概率分布。在此基础上，将此概率分布作为新的贝叶斯网络中模型参数节点概率分布的输入，这一新的贝叶斯网络可用来对关联来源的层次主客观信息集进行融合。

下面首先研究多源层次客观数据集基于层次贝叶斯的融合实现。利用 3.3.3 节中的模型、层次贝叶斯方法以及 OpenBUGS 软件，来实现多源层次客观数据的融合，从而得到模型参数的后验概率分布，为基于贝叶斯网络的多源层次信息融合提供底层节点概率分布的输入。在此基础上，研究多源层次主客观信息集基于贝叶斯网络的融合实现，利用 3.4.2 节中的模型、贝叶斯网络推理方法以及 AgenaRisk 软件^[142]，来实现多源层次主客观信息的融合，并在此基础上对系统的可靠性进行评估。

(1) 独立来源的层次客观数据集基于层次贝叶斯的融合实现

根据 3.3.3 节中独立来源的层次客观数据的模型，利用层次贝叶斯方法，可以构建多源层次客观数据集融合的表达式：

$$\begin{aligned}
 p(\Theta | D^{P/F}, D^{Life}, D^{Deg}) &\propto \pi(\Theta) \times L(D^{P/F}, D^{Life}, D^{Deg} | \Theta) \\
 &= \pi(\Theta) \times \prod_{N_k^{P/F} \in A^{P/F}} L_k^{P/F}(\mathbf{y}_k^{P/F}, \mathbf{x}_k^{P/F}, \mathbf{t}_k^{P/F} | \theta_k^{P/F}) \times \\
 &\quad \prod_{N_k^{Life} \in A^{Life}} L_k^{Life}(\mathbf{t}_k^L, \mathbf{t}_k^F, \mathbf{t}_k^R | \theta_k^{Life}) \times \\
 &\quad \prod_{N_k^{Deg} \in A^{Deg}} L_k^{Deg}(\mathbf{g}_k^{Deg}, \mathbf{t}_k^{Deg} | \theta_k^{Deg})
 \end{aligned} \tag{3-14}$$

式中， Θ 为独立来源的层次客观数据集 $D^{P/F}$ 、 D^{Life} 和 D^{Deg} 对应节点的模型参数， $\pi(\Theta)$ 为模型参数的先验分布， $L(D^{P/F}, D^{Life}, D^{Deg} | \Theta)$ 为式(3-10)所示的似然函数， $p(\Theta | D^{P/F}, D^{Life}, D^{Deg})$ 为融合了数据集 $D^{P/F}$ 、 D^{Life} 和 D^{Deg} 所包含信息的模型参数的后验分布。

式(3-14)主要是用来融合数据集 $D^{P/F}$ 、 D^{Life} 和 D^{Deg} 并得到模型参数 Θ 的概率分布（后验分布）。多源层次信息集中的主观信息并未在此式中进行融合，因此采用无信息先验分布来获得 $\pi(\Theta)$ 。本文采用共轭先验分布、大区间上的均匀分布和无信息先验分布来给定模型参数 Θ 的先验分布，以简化后验分布的表达式并提高 MCMC 抽样的效率。

为了得到模型参数 Θ 的后验分布，需要利用 MCMC 方法来对后验分布进行抽样，并在此基础上得到模型参数近似的概率分布。本文利用 OpenBUGS 软件来实现 MCMC 方法并获得模型参数的样本。具体的算法结构与第三章中图 2-5 的算法结构类似，只需将对应的先验分布和似然函数进行修改，即可构建针对式(3-14)的算法实现，在此不再赘述。

(2) 多源层次主客观信息集基于贝叶斯网络的融合实现

在以上系统模型、数据模型以及独立来源层次客观数据集融合实现的基础上，要实现多源层次主客观信息集的融合，需要对关联来源客观信息集进行有效的融合。关联来源主客观信息集主要包括：数据信息相互覆盖的层次寿命数据（Overlapped Lifetime Data）、量化的主观信息集以及独立来源层次客观数据集融合得到的模型参数概率分布。信息相互覆盖的层次寿命数据是指从同一可靠性信息源（如同一可靠性试验）收集得到的系统不同层次的寿命数据。如图 3-1 所示的系统，在系统整机的寿命试验中得到系统的故障时间为 $t_{S_0}^{OL}$ ，与此同时还收集到了子系统节点 S_1 的故障时间为 $t_{S_1}^{OL}$ 且有 $t_{S_1}^{OL} = t_{S_0}^{OL}$ ，底层节点 C_2 的故障时间为 $t_{C_2}^{OL}$ 且有 $t_{C_2}^{OL} < t_{S_0}^{OL}$ ，以及底层节点 C_6 的故障时间为 $t_{C_6}^{OL}$ 且有 $t_{C_6}^{OL} < t_{S_0}^{OL}$ 。由于系统 S_0 的故障时间与子系统和零部件的故障时间相关联，系统的故障时间信息包含了部分子系统和零部件的故障时间信息。这些故障时间数据不能作为相互独立的数据来进行建模分析。此时，需要将图 3-9 和图 3-11 所建立的贝叶斯网络进行拓展，得到信息

相互覆盖的层次寿命数据的贝叶斯网络模型如图 3-13 所示。

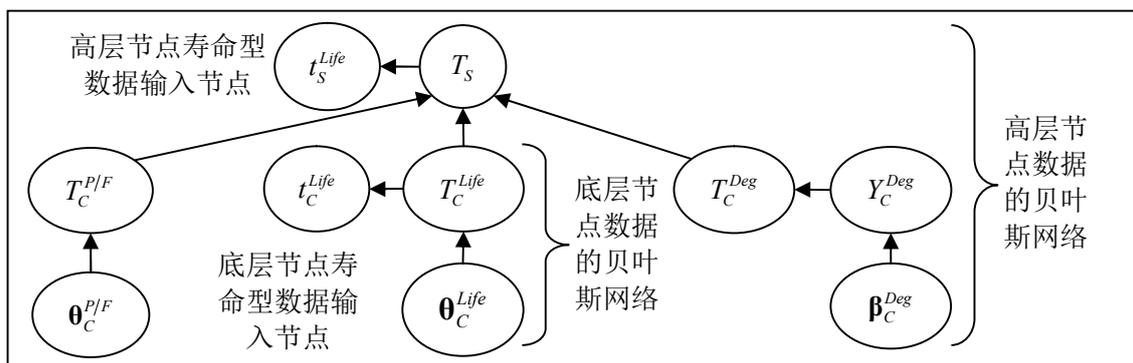


图 3-13 信息相互覆盖的层次寿命数据的贝叶斯网络模型

该贝叶斯网络的定性部分描述了高层节点寿命型数据输入节点 t_S^{Life} ，通过其对应高层节点寿命随机变量 T_S 对应的贝叶斯网络，来与模型参数 $\theta_C^{P/F}$ 、 θ_C^{Life} 和 β_C^{Deg} 建立关联关系；以及底层节点寿命型数据输入节点 t_C^{Life} ，通过其对应底层节点寿命随机变量 T_C^{Life} 与模型参数 θ_C^{Life} 建立关联关系。贝叶斯网络的定量部分与图 3-11 的定量部分相同。图 3-11 与图 3-13 所示贝叶斯网络的关键不同点在于：图 3-13 所示的贝叶斯网络中，高层节点寿命数据输入与底层节点寿命数据输入所依赖的贝叶斯网络存在重叠的部分。这是利用贝叶斯网络的模型结构，来对相互覆盖的层次寿命数据进行建模，通过贝叶斯网络模型的不确定推理方法，来应对信息的覆盖并将其进行融合。

根据图 3-4 所示的多源层次信息融合基本框架，整合图 3-11、图 3-12 和图 3-13 所示的贝叶斯网络模型，即可构建融合多源层次主客观信息的贝叶斯网络模型，如图 3-14 所示。该贝叶斯网络所描述的系统为两层结构的层次系统，主要包括高层节点和底层节点，其中高层节点为寿命型数据对应的节点，而底层节点中包含了成败型、寿命型和退化型数据对应的节点。该贝叶斯网络所描述的多源层次信息包含了三大信息：独立来源层次客观数据集融合得到的模型参数的信息（后验概率分布）、层次覆盖寿命数据的信息以及多层次主观信息。针对这样的系统结构和数据类型，该贝叶斯网络的定性部分以模型参数节点为父节点构建两大部分贝叶斯网络：一部分是描述层次覆盖寿命数据与模型参数关联关系的贝叶斯网络，另一部分为层次主观信息与模型参数关联关系的贝叶斯网络。该贝叶斯网络的定量部分主要包括以下关键方面：模型参数节点概率分布设定为独立来源层次客观数据集融合得到的模型参数的概率分布；底层节点和高层节点量化信息输入节点的条件概率分布，应根据主观信息的量化形式来选择确定。该贝叶斯网络其他定性和定量部分的具体描述，可以参见图 3-12 和图 3-13 对应贝叶斯网络的描述。

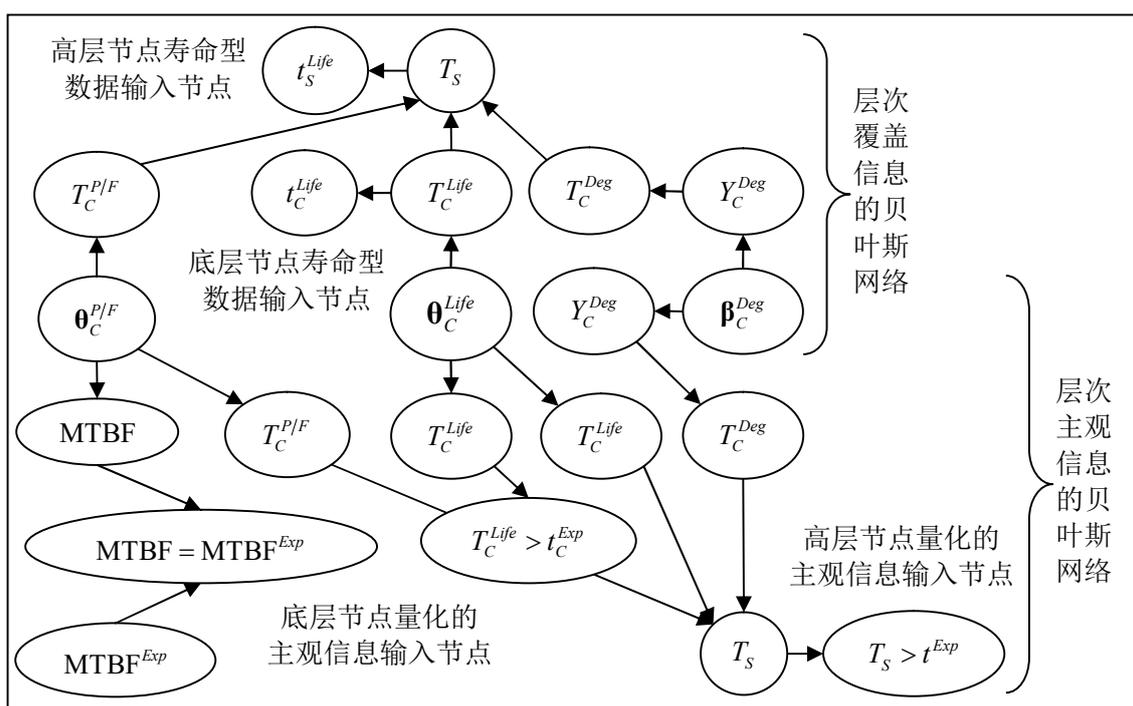


图 3-14 多源层次主客观信息融合的贝叶斯网络模型

对于图 3-14 所示贝叶斯网络，本文利用贝叶斯网络计算软件 AgenaRisk^[142]来对其进行求解。该软件的核心算法是基于动态离散（Dynamic Discretization）的贝叶斯网络推理算法（Propagation Algorithms）^[144-146]。应用 AgenaRisk 来对图 3-14 所示贝叶斯网络的求解，主要包含以下关键步骤：

- 1) 按照节点的连接关系“自底向上”依次完成贝叶斯网络定性部分的绘制。
- 2) 按照节点的依赖关系“自底向上”依次给定每个节点的定量部分。
- 3) 根据“寿命型数据输入节点”和“量化的主观信息输入节点”定量部分的设置，以及上文给出的对应节点证据输入的要求，设置软件中节点的证据输入。
- 4) 设置求解算法的参数，通过软件对所建立的贝叶斯网络进行求解。
- 5) 根据可靠性评估的需求，导出软件的计算结果。

3.5 算例分析

近年来随着重型机床性能指标的逐步提升，主轴系统作为影响机床性能指标的关键子系统，其性能保持性和稳定性逐渐成为主机厂和用户厂所关注的焦点。在机床设计研制阶段，如何对主轴系统进行有效的可靠性评估，并为可靠性设计、试验和验证提供技术支撑，已成为该阶段重型数控机床可靠性工作的重点。目前，随着寿命周期可靠性工作的开展以及可靠性数据的收集，组成主轴系统的关键零

部件，如主轴、主轴轴承和松拉刀机构等的可靠性数据逐渐得到积累和丰富，并形成了涵盖成败型、寿命型、退化型等客观数据以及专家经验信息的多源层次信息集。本章将通过某重型数控机床主轴系统的多源层次信息集的分析，来对本文所提出的模型和所构建的方法进行示例应用。

考虑到重型数控机床的主轴系统多为串并联结构，且出于方法示例性说明以及主机厂信息的保护，本文所采用的系统结构为简化了的主传动系统结构。多源层次信息集是对原有信息进行适当处理之后，保留信息集的多源性、层次性、覆盖性和主客观信息共存等特点所形成的示例信息集。

3.5.1 多源层次信息集

某主轴系统简化的系统可靠性框图如图 3-15 所示。该系统包含零部件、子系统和系统三层结构，其中 C_1 、 C_2 、 C_3 和 C_4 为底层节点并构成零部件层， S_1 和 S_0 为高层节点并分别构成子系统层和系统层。系统各零部件、子系统和系统对应的可靠性信息的概要归纳如表 3-1 所示。

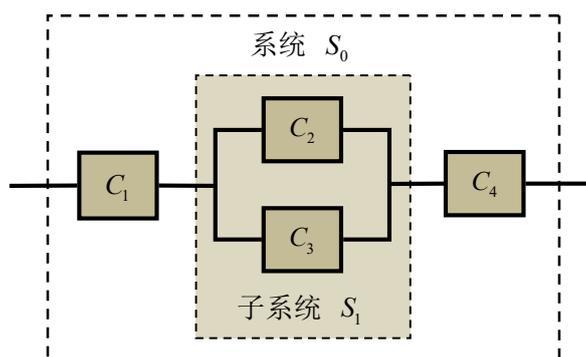


图 3-15 主轴系统简化可靠性框图模型

表 3-1 中主轴可靠性信息主要包括多源层次客观信息集和多源层次主观信息集两大部分，其中多源层次客观信息集又可分为相互独立的客观信息集和层次覆盖的客观信息集。层次独立的客观信息集指信息集中的所有节点的可靠性数据的来源相互独立（如各个节点分别独立展开的可靠性试验收集到的数据），各节点数据的建模和分析不需要考虑节点间数据的重叠和覆盖等问题。层次覆盖信息集指信息集中不同节点的可靠性数据的来源相互关联（如同一可靠性试验中同时收集到的系统中高层节点及其子节点的数据），对应节点数据的建模和分析需要考虑节点间数据的重叠和覆盖等问题。多源层次主观信息集主要包括独立来源的底层节点的主观信息，在信息的量化、融合时不需要考虑节点间信息的覆盖问题。

表 3-1 主轴系统的多源层次信息集的组成结构

信息类型	系统节点对应信息的概要描述
客观 信息集	层次独立 系统节点 C_1 、 C_2 、 C_3 、 C_4 、 S_0 对应独立信息来源的可靠性数据，其中 C_1 对应成败型数据、 C_2 和 C_3 对应寿命型数据、 C_4 对应退化型数据、 S_0 对应寿命型数据。
	层次覆盖 系统节点 C_2 、 C_3 和 S_1 对应同一信息来源的可靠性数据，在获取 S_1 的寿命型数据的同时，获得了 C_2 和 C_3 的部分寿命信息。
主观 信息集	底层节点 系统节点 C_1 平均故障时间以及节点 C_4 在给定时间点不发生故障的概率的主观评价
	高层节点 系统节点 S_0 在给定时间点不发生故障的概率

在对多源层次信息集进行概要描述和说明的基础上，表 3-2、表 3-3 和表 3-4 依次给出了主轴系统对应的多源层次信息集，其中表 3-4 所示的主观信息是经过量化处理之后的结果。

表 3-2 主轴系统的层次独立客观信息集

零部件 C_1 对应的成败型数据（每次试验的样本都为 15 个，时间：h）										
成功数/样本数	15/15	15/15	13/15	13/15	13/15	12/15	11/15	11/15	7/15	6/15
样本服役时间	96	192	288	384	480	576	672	768	864	960
零部件 C_2 对应的故障时间数据（10 个样本，时间：h）										
2248	1360	2177	1880	2110	2142	1347	1659	1548	2496	
零部件 C_3 对应的故障时间数据（10 个样本，时间：h）										
168	733	1100	2694	888	4303	4731	1209	1468	1753	
零部件 C_4 对应的退化型数据（10 个样本，部分数据省略，时间：h）										
观测时间	48	96	144	192	240	288	336	384	432	480
样本 1	0.969	0.975	0.973	0.954	0.940	0.934	0.900	0.907	0.894	0.906
样本 2	0.972	0.945	0.906	0.876	0.849	0.799	0.783	0.752	0.707	0.691
系统 S_0 对应的寿命型数据（10 个样本，时间：h）										
2130	1644	2548	188	2072	222	339	34	880	706	

表 3-3 主轴系统的层次覆盖客观信息集

C ₂ 、C ₃ 和S ₁ 对应的层次覆盖寿命型数据（10个样本，时间：h）										
S ₁	4430	2606	5036	1699	2478	2354	1532	3275	2767	2642
C ₂	1724	--	2573	1699	2478	--	--	1923	--	2090
C ₃	--	2606	--	--	--	2354	562	--	2767	--

表 3-4 主轴系统的多源层次主观信息集

系统节点 C ₁ 平均故障时间的主观评价（主观概率量化）
$MTBF_{C_1} \sim \text{Lognormal}(7.5959, 0.0998)$
系统节点 C ₄ 在给定时间点不发生故障概率的主观评价（主观概率量化）
$\Pr(T_{C_4} > 500) = 0.94, \Pr(T_{C_4} > 1000) = 0.82, \Pr(T_{C_4} > 1500) = 0.67, \Pr(T_{C_4} > 2000) = 0.52$

3.5.2 信息集的层次贝叶斯模型与贝叶斯网络模型

表 3-2、表 3-3 和表 3-4 所示的多源层次信息集的融合，根据 3.4 节中构建的基本框架，首先需要对表 3-2 所示的独立来源的多源层次数据进行融合。根据 3.3 节中描述的独立来源的分布于系统不同层次的成败型、寿命型和退化型数据的建模方法，依次建立表 3-2 中对应数据的模型如下。

1) 成败型数据模型

考虑到零部件 C₁ 的物理特性、技术成熟度以及该零部件的历史经验信息，假设其可靠性分布为指数分布。令 $Y_{C_1}^{P/F}(t_i)$ 为描述观测时间点 t_i 成败型试验的随机变量，该随机变量服从如下式所示的二项分布：

$$Y_{C_1}^{P/F}(t_i | \theta_{C_1}) \sim \text{Binomial}(y_i; n_i, \exp(-\lambda_1 t_i)) \quad (3-15)$$

式中， $\theta_{C_1} = \{\lambda_1\}$ ， y_i 为在样本服役时间为 t_i 时所开展试验中通过试验的样本个数（成功数）， x_i 则为该次试验中的总样本个数。

此时，表 3-2 中的成败型数据所包含的信息可通过似然函数描述为：

$$L_{C_1}^{P/F}(\mathbf{y}_{C_1}^{P/F}, \mathbf{x}_{C_1}^{P/F}, \mathbf{t}_{C_1}^{P/F} | \theta_{C_1}) \propto \prod_{i=1}^{10} \left\{ C_{x_i}^{y_i} (\exp(-\lambda_1 t_i))^{y_i} (1 - R(\exp(-\lambda_1 t_i)))^{x_i - y_i} \right\} \quad (3-16)$$

式中， $\mathbf{y}_{C_1}^{P/F}$ 、 $\mathbf{x}_{C_1}^{P/F}$ 分别对应于表 3-2 中“成功数”和“样本数”的数据， $\mathbf{t}_{C_1}^{P/F}$ 则对应于表中“样本服役时间”的数据。

2) 底层节点寿命型数据模型

考虑到零部件 C₂ 和 C₃ 的物理特性、技术成熟度和历史信息，分别用对数正态

分布模型和威布尔分布模型对其可靠性进行建模，即 $T_2 \sim \text{Lognormal}(\mu_2, \sigma_2)$ 和 $T_3 \sim \text{Weibull}(\beta_3, \eta_3)$ 。由于表 3-2 中的寿命型数据不存在截尾的情况，根据 3.3.3 节中关于寿命型数据的建模方法，可以将表 3-2 中的寿命型数据包含的信息通过似然函数描述为：

$$L_{C_2}^{Life}(\mathbf{t}_{C_2}^F | \boldsymbol{\theta}_{C_2}) = \prod_{i=1}^{10} \frac{1}{\sqrt{2\pi}t_i\sigma_2} \exp\left(-\frac{1}{2}\left(\frac{\ln t_i - \mu_2}{\sigma_2}\right)^2\right) \quad (3-17)$$

$$L_{C_3}^{Life}(\mathbf{t}_{C_3}^F | \boldsymbol{\theta}_{C_3}) = \prod_{i=1}^{10} \frac{\beta_3}{\eta_3} \left(\frac{t_i}{\eta_3}\right)^{\beta_3-1} \exp\left(-\left(\frac{t_i}{\eta_3}\right)^{\beta_3}\right) \quad (3-18)$$

式中， $\boldsymbol{\theta}_{C_2} = \{\mu_2, \sigma_2\}$ ， $\boldsymbol{\theta}_{C_3} = \{\beta_3, \eta_3\}$ ， $\mathbf{t}_{C_2}^F$ 和 $\mathbf{t}_{C_3}^F$ 分别对应于表 3-2 中 C_2 和 C_3 的“故障时间数据”。

3) 退化型数据模型

考虑到零部件 C_4 存在的线性退化特性，采用线性退化轨迹模型来对其进行建模，有 $Y^{Deg}(t_{ij} | \boldsymbol{\gamma}^{Deg}) = \alpha_4 - t_{ij}\gamma_i^{-1}$ 且用 $\gamma_i \sim \text{Weibull}(\beta_4, \eta_4)$ 来描述样本之间的差异性。此时 C_4 的可靠性模型可描述成 $T_4 \sim \text{Weibull}(\beta_4, \eta_4(\alpha_4 - Y_4^D))$ ，其中 α_4 为性能退化初始值， Y_4^D 为性能退化阈值。根据 3.3.3 节中关于退化型数据的建模方法，可以将表 3-2 中退化型数据包含的信息通过似然函数描述为：

$$L_{C_4}^{Deg}(\mathbf{g}_{C_4}^{Deg}, \mathbf{t}_{C_4}^{Deg} | \boldsymbol{\theta}_{C_4}^{Deg}) = \prod_{i=1}^2 \prod_{j=1}^{10} \phi\left(\frac{g_{ij} - (\alpha_4 - t_{ij}\beta_i^{-1})}{\sigma_4}\right) \quad (3-19)$$

式中， $\boldsymbol{\theta}_{C_4}^{Deg} = \{\beta_4, \eta_4, \sigma_4\}$ ， $\mathbf{g}_{C_4}^{Deg}$ 对应于表 3-2 中 C_4 的“性能退化观测值”， $\mathbf{t}_{C_4}^{Deg}$ 对应于“观测时间点”。

4) 高层节点寿命型数据模型

对于系统节点 S_0 所对应的寿命型数据，需要利用层次结构的可靠性建模方法来获得节点 S_0 的可靠性函数。对于图 3-15 所示的系统，结合各底层节点的可靠性模型，可以得到 S_0 的可靠性模型如下：

$$\begin{aligned} R_{S_0}(t | \boldsymbol{\theta}_{S_0}) &= R_1(t)(R_2(t) + R_3(t) - R_2(t)R_3(t))R_4(t); \\ R_1(t | \boldsymbol{\theta}_{C_1}) &= \exp(-\lambda_1 t), R_2(t | \boldsymbol{\theta}_{C_2}) = 1 - \Phi((\ln t - \mu_2)/\sigma_2), \\ R_3(t | \boldsymbol{\theta}_{C_3}) &= \exp(-(t/\eta_3)^{\beta_3}), R_4(t | \boldsymbol{\theta}_{C_4}) = \exp\left(-\left(t/(\eta_4(\alpha_4 - Y_4^D))\right)^{\beta_4}\right) \end{aligned} \quad (3-20)$$

式中， $\boldsymbol{\theta}_{S_0} = \{\lambda_1, \mu_2, \sigma_2, \beta_3, \eta_3, \beta_4, \eta_4\}$ ， $\boldsymbol{\theta}_{C_4} = \{\beta_4, \eta_4\}$ 。

此时，可以将表 3-2 中 S_0 的寿命型数据包含的信息通过似然函数描述为：

$$L_{S_0}^{Life}(\mathbf{t}_{s_0}^F | \boldsymbol{\theta}_{S_0}) = \prod_{i=1}^{10} f_{S_0}(t_i | \boldsymbol{\theta}_{S_0}) \quad (3-21)$$

式中, $f_{S_0}(t_i | \boldsymbol{\theta}_{S_0})$ 为 S_0 的故障概率密度函数, 可通过 $R_{S_0}(t | \boldsymbol{\theta}_{S_0})$ 对时间 t 求导数得到。

当建立了表 3-2 中各独立来源数据的模型之后, 根据 3.4.3 节中描述的基于层次贝叶斯的独立来源的层次客观数据集融合的方法, 可以构建如下的融合表达式:

$$\begin{aligned} p(\boldsymbol{\Theta} | D^{P/F}, D^{Life}, D^{Deg}) &\propto \pi(\boldsymbol{\Theta}) \times L(D^{P/F}, D^{Life}, D^{Deg} | \boldsymbol{\Theta}) \\ &= \pi(\boldsymbol{\Theta}) \times L_{C_1}^{P/F}(\mathbf{y}_{C_1}^{P/F}, \mathbf{x}_{C_1}^{P/F}, \mathbf{t}_{C_1}^{P/F} | \boldsymbol{\theta}_{C_1}) \times \\ &\quad L_{C_2}^{Life}(\mathbf{t}_{C_2}^F | \boldsymbol{\theta}_{C_2}) L_{C_3}^{Life}(\mathbf{t}_{C_3}^F | \boldsymbol{\theta}_{C_3}) L_{S_0}^{Life}(\mathbf{t}_{S_0}^F | \boldsymbol{\theta}_{S_0}) \times \\ &\quad L_{C_4}^{Deg}(\mathbf{g}_{C_4}^{Deg}, \mathbf{t}_{C_4}^{Deg} | \boldsymbol{\theta}_{C_4}^{Deg}) \end{aligned} \quad (3-22)$$

式中, $D^{P/F} = \{\mathbf{y}_{C_1}^{P/F}, \mathbf{x}_{C_1}^{P/F}, \mathbf{t}_{C_1}^{P/F}\}$, $D^{Life} = \{\mathbf{t}_{C_2}^F, \mathbf{t}_{C_3}^F, \mathbf{t}_{S_0}^F\}$, $D^{Deg} = \{\mathbf{g}_{C_4}^{Deg}, \mathbf{t}_{C_4}^{Deg}\}$, $\boldsymbol{\Theta} = \{\boldsymbol{\theta}_{S_0}, \sigma_4\}$; $\pi(\boldsymbol{\Theta})$ 为模型参数的先验分布, 在多源层次客观数据集融合时采用无信息先验分布来作为模型参数的先验分布, 各模型参数的先验分布如表 3-5 所示。

在完成表 3-2 中信息融合的基础上, 根据 3.4 节构建的基本框架, 进一步需要对表 3-3 和表 3-4 所示的同一来源的层次覆盖数据以及独立来源的主观信息进行融合。根据 3.5.2 节中描述的贝叶斯网络建模方法, 针对表 3-3 和表 3-4 中所包含的信息, 可以建立融合表 3-3 和表 3-4 所包含信息的贝叶斯网络如图 3-16 所示。

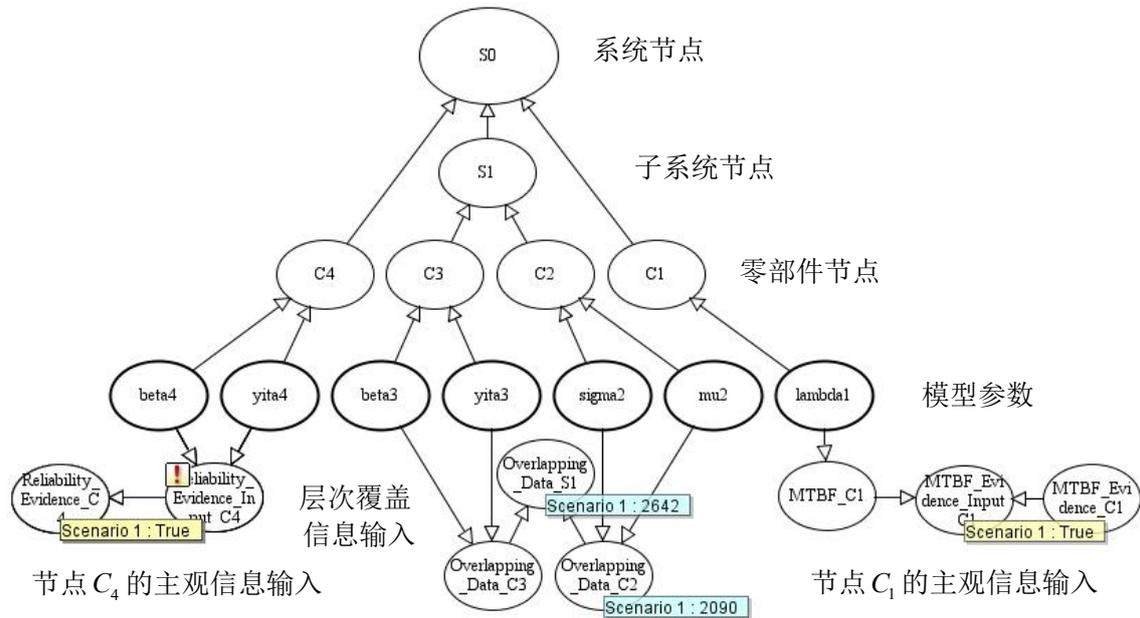


图 3-16 层次覆盖数据和主观信息融合的贝叶斯网络模型

该贝叶斯网络模型是利用 3.5.2 节中描述的层次覆盖数据的贝叶斯网络建模方

法和主观信息输入的贝叶斯网络建模方法，在软件 AgenaRisk 中建模实现的。图中模型参数的节点对应的边缘概率分布为式(3-22)中模型参数的后验分布。零部件节点的条件概率分布是各节点可靠性模型与对应模型参数关系的具体表达，如 $T_{C_4} \sim \text{Weibull}(\beta_4, \eta_4)$ 。高层节点的条件概率分布则是系统层次结构关系的逻辑表达，如 $T_{S_1} \sim \max(T_{C_2}, T_{C_3})$ 。

至此，主轴系统多源层次信息集所包含的信息，通过层次贝叶斯模型和贝叶斯网络进行了建模表达，通过对模型的求解即可获得模型参数的估计，并在此基础上进行系统可靠性的评估。

3.5.3 系统可靠性评估

对于式(3-22)和图 3-16 所示模型的求解，分别通过 OpenBUGS 和 AgenaRisk 来实现。首先通过 OpenBUGS 对式(3-22)所示的后验分布进行 MCMC 抽样，并对后验样本进行概率分布的近似拟合，以得到图 3-16 中模型参数节点边缘分布的输入。模型参数的估计结果及后验分布的概率分布近似拟合结果如表 3-5 所示。

表 3-5 模型参数的估计结果

模型参数	统计特征值		后验置信区间		模型先验分布	后验分布近似拟合
	均值	方差	2.5%	97.5%		
λ_1	5.16E-04	8.34E-05	3.67E-04	6.91E-04	Gamma(0,2000)	Gamma(38.263,1.347E-05)
μ_2	7.546	0.08112	7.384	7.705	Uniform(0,100)	Lognormal(2.021,0.011)
σ_2	0.2514	0.07141	0.1559	0.426	Uniform(0,100)	Lognormal(-1.415,0.256)
β_3	1.248	0.3086	0.6982	1.905	Uniform(0,10)	Gamma(15.990,0.078)
η_3	2170	599.3	1196	3541	Gamma(1,0.0005)	Gamma(13.82,157.051)
β_4	1.813	0.201	1.4501	2.2334	Uniform(0,10)	Lognormal(0.599,0.111)
η_4	2550	347	1934	3308	Gamma(1,0.0005)	Lognormal(7.835,0.136)
σ_4	0.01054	0.001908	0.007578	0.01507	Uniform(0,10)	Lognormal(-4.568,0.174)

将表 3-5 中模型参数的后验分布代入到图 3-16 所示的贝叶斯网络模型中，通过 AgenaRisk 来开展基于动态离散的贝叶斯网络推理，获得融合多源层次信息后各节点的边缘概率分布。此基础上，通过对各节点边缘概率分布的归纳，可以得到主轴系统各层次节点可靠性指标的评估结果，如表 3-6 和图 3-17 所示。

评估结果包括了主轴系统 S_0 的 MTBF 估计值、故障概率密度函数的分布大体情形以及特征时间点 $t = 500, 1500, 2000$ 时主轴系统的可靠度。通过对多源层次信息的融合，该结果一方面直接反映了多源层次信息所包含的系统可靠性信息，另一

方面也间接描述了系统评估结果不确定性的主要来源。评估方法一方面实现了系统中各层次节点可靠性的综合评估；另一方面构建了系统后续分析的贝叶斯网络模型，可以为进一步的灵敏度分析和重要度分析提供基本框架。

表 3-6 主轴系统各层次节点可靠性评估结果

系统节点	故障时间 (h)		系统节点	故障时间 (h)		系统节点	故障时间 (h)	
	均值	方差		均值	方差		均值	方差
S_0	1070	776	C_1	2001	2035	C_3	1547	1040
S_1	2231	726	C_2	1960	477	C_4	2274	1349

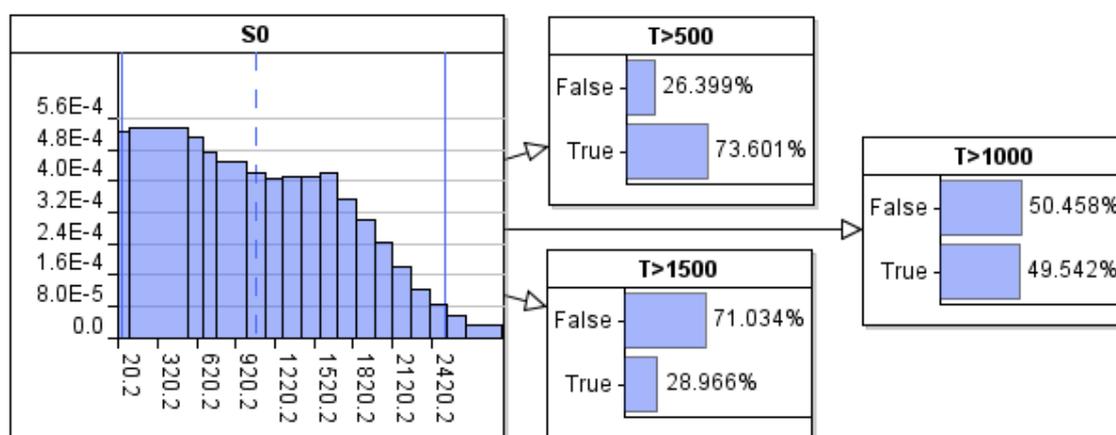


图 3-17 主轴系统可靠性评估结果

3.6 本章小结

本章针对重型数控机床多源层次信息集中信息的多样性、数据的覆盖性以及信息的主客观共存性等给可靠性建模与评估带来的挑战，从多类型数据建模、层次覆盖信息处理和主客观信息融合等方面，研究了重型数控机床基于多源层次信息集的可靠性建模与评估技术。首先，研究提出了系统层次结构以及多种类型可靠性数据的建模框架。在此框架下实现了信息来源相互独立且分布于系统不同层次的成败型、寿命型和退化型数据的建模。然后，在此基础上应用贝叶斯信息融合方法与贝叶斯网络理论构建了多源层次信息融合的基本框架。在此框架下重点研究了针对独立来源的层次客观数据集的融合方法、针对层次覆盖客观数据集的融合方法以及针对多源层次主客观信息集的融合方法。独立来源的层次客观数据集的融合方法，借助了贝叶斯信息融合技术对层次多类型数据的计算优势。层次覆盖客观数据和主客观信息集的融合方法，利用了贝叶斯网络理论对关联关系的

建模与不确定性推理的处理优势。最后通过算例对建模和评估方法进行了示例展示。算例分析表明：多源层次信息集的融合能够解决重型数控机床需要综合考虑零部件、子系统和系统“深度”建模与评估的要求，能够应对数据形式多样、层次数据覆盖和主客观信息共存等问题的挑战。融合多源层次信息集的可靠性建模与评估，与传统采用某一局部（零部件、子系统或系统）数据的建模与评估相比，模型更为全面、评估结果更为精确；并且所得到的贝叶斯网络模型和所形成的分析方法可为后续的分析提供模型基础和信息融合的平台。

第四章 基于性能检测数据的重型数控机床可靠性建模与评估

近年来随着信号获取与传感技术的发展,针对系统关键性能指标的获取与监测已经成为可能。性能数据由于其在信息量和实时性上的优势,逐渐取代传统“宏观”的寿命数据和“深度”的多源层次信息,成为系统建模与评估的关键支撑信息。在这样的背景下,基于性能检测数据的可靠性建模与评估技术逐渐在重型数控机床寿命周期的可靠性工作中受到关注。然而,多数性能检测数据模型与评估方法都是沿用现有简单机床系统的性能退化过程模型与方法,这些模型与方法一方面难以应对重型数控机床性能演变速率形式多、个体差异性大、性能波动性强等特性,另一方面不能满足重型数控机床小批量定制下主机厂和用户厂协同检测评估以及结果不确定性量化表征的实际需求。本章将针对重型数控机床的本质特性和实际需求,研究适用于重型数控机床的性能演变过程模型与可靠性评估方法,为重型数控机床寿命周期的可靠性工作提供技术支撑。

4.1 引言

随着重型数控机床逐渐进入寿命周期中研制阶段的后期和使用阶段的初期,针对重型数控机床的可靠性评定与验证成为重型数控机床寿命周期可靠性工作的“分水岭”:一方面机床整机的可靠性水平将在主机厂与用户厂的协同下进行考核验证,其结果直接影响着机床研制的成败;另一方面机床可靠性工作将会从主机厂为主导的以提高固有可靠性为目的的可靠性工作,向用户厂为主导的以保证使用可靠性为目的的方向发展。

多源层次信息的获取及该信息驱动下可靠性技术的落实,使得研制阶段重型数控机床关键功能部件、子系统乃至整机可靠性的提高得到了保障。机床研制阶段基于多源层次信息的可靠性评估技术主要用来深入挖掘机床功能部件、子系统和系统之间的可靠性关系并对其进行全面描述。该方法为机床的研制和定型提供了宝贵的技术和信息支撑,但是该方法需要较长时间数据和信息的积累,并且多种信息源的引入往往使得其评估结果难以为用户厂等关注整机性能水平的单位所接受。当机床进入研制阶段的末期和使用阶段的初期这一关键“分水岭”阶段,机床在有效时间内实现高精度和高置信度的整机可靠性验证与评估成为寿命周期工作的关键核心。此时基于故障时间数据和基于多源层次信息集的可靠性评估技术已经难以适用,亟需研究以整机为出发点在较短时间、较少样本下高置信度的可靠性评估技术。

面对这样的技术和工程需求，回顾基于性能退化数据的可靠性技术的发展历程可知：基于性能退化数据的可靠性建模与评估技术是在常规的基于寿命数据的技术和方法在高可靠长寿命产品的应用中遇到挑战时所发展起来的^[68-73]。常规的基于寿命数据的可靠性试验、建模和评估技术往往难以在有效的时间内获得充足的寿命数据来对高可靠长寿命产品的可靠性进行高置信度的评估^[73]。在这样的背景下，借力信号获取与传感技术的发展以及故障机理与征兆联系研究的不断深入，利用产品关键性能指标的演变来研究产品的可靠性成为解决高可靠长寿命产品可靠性建模评估的关键突破口。近年以来，基于性能退化数据的产品可靠性试验^[147-149]、建模^[150-151]与评估^[152-153]技术得到了学术界广泛关注，且在材料、试件、电子元器件、消费类电子产品和简单机电产品上得到了应用，并逐步向复杂产品的研究与应用拓展^[154-155]。

由于重型数控机床不同于普通机床产品，往往表现出系统结构复杂、研制周期长、制造成本高、小批量定制等特性。对于其性能指标的演变而言，由于机床结构、使用环境和任务要求的特殊性使其性能演变轨迹模式多样并呈现出个体差异性，如线性/非线性波动型、单调型、反 S 型等^[155]；同时，工作应力动态多变使得其性能演变过程也呈现出较强的时间关联性和较大的性能波动性等特征。此外，当处于研制阶段的末期和使用阶段的初期时，主机厂会在机床交付前进行整机的性能检测试验。用户厂会在机床使用初期进行整机的性能演变跟踪测定；在此基础上，双方会协同对机床的性能进行评估验证，并对评估结果的不确定性进行量化表征，以期得到一致的评估结果。多数用于数控机床的性能演变过程模型与评估方法都是沿用简单机床系统的模型与方法。这些模型与方法一方面难以应对重型数控机床性能演变速率形式多、个体差异性大、性能波动性强等关键特性，另一方面不能满足重型数控机床小批量定制下主机厂和用户厂协同考核评估以及结果不确定性量化表征的实际需求。这些特性决定了重型数控机床基于性能检测数据的可靠性建模与评估技术的研究和难点。本章借重于机械状态监测、故障诊断、寿命预测等技术的研究发展，在传统基于性能退化数据的系统可靠性建模与评估技术的基础上，研究基于随机过程的新型性能演变过程模型并将随机效应模型引入到所建立的性能演变过程模型中，以实现重型数控机床性能退化特性的准确描述；在此基础上针对所建立的性能演变过程模型，研究基于贝叶斯方法的性能检测数据分析与可靠性评估方法，以此实现主机厂与用户厂性能检测数据的融合评估以及评估结果不确定的有效表征。

4.2 重型数控机床的性能检测数据

重型数控机床的性能检测数据是指针对机床的关键特性与功能,通过采用适当的测量仪器与技术来获取,并经过信号处理、参数提取与融合所得,能够反应机床内在状态和演变趋势的可靠性数据。在实际工程中可用于重型数控机床可靠性建模与评估的整机性能检测数据主要包括:主机厂在机床交付前整机性能检测试验所获得的数据和用户厂在机床使用初期整机性能监测所获得的数据。这两种来源的数据虽然都是与整机性能检测相关的数据,但是由于数据获取的环境条件和工作应力的不同,可能表现出一定的差异性。

主机厂整机性能退化检测往往是在标定的环境条件下,根据相应的试验标准来对机床施加模拟实际工况的应力所获得的性能检测数据,如重型数控机床在试验用厂房环境条件下加工标准试件所获得的性能检测数据。由于环境条件和工作应力相对稳定且符合机床设计的相应指标,使得这一类性能检测数据能够较好的反应机床的固有可靠性。主机厂性能检测试验的开展和数据的收集是在设计好的试验方案下进行,性能检测数据的完整性能够得到保障。基于主机厂所收集的整机性能检测数据所开展的机床可靠性建模与评估,能够对机床在理想状态下的可靠性进行较好的评估,但是对于机床在实际情形下的可靠性却难以进行准确的预测。

用户厂整机性能指标的监测往往是在实际的环境条件下,机床在经历所施加的工作任务的同时所产生的性能检测数据,如重型数控机床在开放厂房环境条件下加工实际零件所获得的性能检测数据。由于环境条件和任务应力往往存在一定的波动性且会偏离机床设计的相应指标,使得这类性能检测数据多与使用可靠性相关联。由于用户厂对性能检测指标的监测是伴随着机床的服役所开展的,工作任务的完成是其首要考虑的因素,因此性能检测数据的收集往往会受到人员、仪器、机床的任务计划的干扰和限制,使得性能检测数据的完整性难以得到保证。基于用户厂所收集的整机性能退化试验数据所开展的机床可靠性建模与评估,虽然能够对机床在实际工况下的可靠性进行评估,但是在实际工况下难免有超出机床标定的环境条件和任务应力的情形,这往往会导致分析评估的结果与机床本身具备的可靠性水平存在一定的偏差。

综上所述,两种来源的性能检测数据虽然在表现形式上可能存在一定的共同性,但是各自所反映出来的机床可靠性水平却存在一定的差异,融合两种来源性能检测数据的可靠性评估是重型数控机床高置信度可靠性评估的关键所在。

4.3 重型数控机床性能检测数据的建模

重型数控机床具有性能演变速率形式多、个体差异性大、性能波动性强等特

点。本文首先研究基于随机过程的性能演变过程模型，然后在此基础上提出多种速率形式下的性能演变过程模型以实现对机床性能演变速率形式多这一特性的应对。在此基础上，将随机影响模型引入到性能演变过程模型中，以实现对机床性能退化个体差异性大和性能波动性强等特性的描述。

4.3.1 基于随机过程的性能演变过程模型

基于随机过程的模型是性能数据建模分析中的主流模型，其中研究和应用较多的模型是基于维纳过程（Wiener Process）的模型^[157-159]和基于伽玛过程（Gamma Process）的模型^[153-154, 162]。下面在介绍这两类模型的基础上，研究引入基于逆高斯过程^[156, 160-161]（Inverse Gaussian Process）的性能演变过程模型。

（1）维纳过程模型

令 $\{Y(t), t \geq 0\}$ 为机床的性能指标的演变过程，当其服从维纳过程时可描述为：

$$Y(t) = \mu\tau(t) + \sigma B(\tau(t)) \quad (4-1)$$

式中， μ 为描述性能演变速率的参数（Drift Parameter）， σ 为描述性能演变过程时间波动性的参数（Volatility Parameter）， $B(\cdot)$ 为标准的布朗运动过程， $\tau(t)$ 为描述性能演变轨迹非线性特性的单调递增函数^[73]或称为时间尺度变换函数（Time Scale Function），当 $\tau(t) = t$ 时该模型即为常见的具有线性演变轨迹的维纳过程模型。

式(4-1)所示的性能演变过程 $Y(t)$ 具有以下性质：

1) $Y(0) = 0$ 且 $Y(t)$ 具有独立增量 $\Delta Y(t) = Y(t + \Delta t) - Y(t)$ ，即增量 $Y(t_2) - Y(t_1)$ 和增量 $Y(t_4) - Y(t_3)$ 在满足 $\forall t_4 > t_3 \geq t_2 > t_1$ 的时间区间上相互独立。

2) 增量 $\Delta Y(t)$ 服从正态分布，即有 $\Delta Y(t) \sim N(\mu\Delta\tau(t), \sigma^2\Delta\tau(t))$ ，其中 $\Delta\tau(t) = \tau(t + \Delta t) - \tau(t)$ 。

此时，性能演变增量 $\Delta Y(t)$ 的概率密度函数可表示为：

$$f(\Delta y(t) | \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi\Delta\tau(t)}} \exp\left(-\frac{(\Delta y(t) - \mu\Delta\tau(t))^2}{2\sigma^2\Delta\tau(t)}\right) \quad (4-2)$$

当给定性能演变过程的阈值为 D 时，基于性能演变过程 $Y(t)$ 的机床故障时间 T 可以定义为：

$$T = \inf\{t: Y(t) \geq D\} \quad (4-3)$$

这意味着当机床的性能演变过程 $Y(t)$ 首次达到给定的阈值 D 时即判定机床发生了故障。性能演变阈值 D 往往是根据机床的性能和功能特性要求预先给定的固定值。基于性能演变过程 $Y(t)$ 所得到的机床故障时间 T 也可称为性能演变过程

$Y(t)$ 的首次穿越时间 (First Passage Time)。

根据维纳过程模型的性质和机床故障时间 T 的定义,可以得到机床的故障时间 T 在经过时间尺度函数 $\tau(t)$ 变换之后服从逆高斯分布,即 $\tau(T) \sim \text{IG}(D/\mu, D^2/\sigma^2)$ 。当 $\tau(T) = T$ 时, 即当 $Y(t)$ 服从线性演变轨迹的维纳过程模型时, 机床的故障时间 $T \sim \text{IG}(D/\mu, D^2/\sigma^2)$ 且其对应的故障概率密度函数和机床的可靠度函数可分别描述为:

$$f(t|\mu, \sigma) = \frac{D}{\sqrt{2\pi t \sigma t}} \exp\left(-\frac{(\mu t - D)^2}{2\sigma^2 t}\right) \quad (4-4)$$

$$R(t|\mu, \sigma) = \Phi\left(\frac{D - \mu t}{\sigma\sqrt{t}}\right) + \exp\left(\frac{2\mu D}{\sigma^2}\right) \Phi\left(-\frac{D + \mu t}{\sigma\sqrt{t}}\right) \quad (4-5)$$

当 $\tau(T)$ 对 T 可导时, 机床的故障时间的概率密度函数可描述为:

$$f(t|\mu, \sigma) = \frac{D}{\sqrt{2\pi\sigma^2\tau(t)^3}} \exp\left(-\frac{(\mu\tau(t) - D)^2}{2\sigma^2\tau(t)}\right) \left| \frac{d\tau(t)}{dt} \right| \quad (4-6)$$

式中, $|\cdot|$ 为绝对值运算, $d\tau(t)/dt$ 为 $\tau(t)$ 对 t 的导数。

维纳过程模型主要用来描述性能演变轨迹非单调递增的性能演变过程。由于其模型参数的物理意义较为明显、首次穿越时间的概率密度可以解析、随机效应和协变量引入方便等原因, 使得其在性能演变过程建模的研究和应用中得到了广泛的关注。关于应用维纳过程模型及其改进模型对性能演变过程的研究综述可参见 Ye 和 Xie 的综述文章^[73]。

(2) 伽玛过程模型

当机床的性能演变过程 $\{Y(t), t \geq 0\}$ 服从形状函数为 $\eta(t)$ 、速率参数为 ω 的伽玛过程时, 其具有以下性质:

- 1) $Y(0) = 0$ 且 $Y(t)$ 具有独立增量 $\Delta Y(t) = Y(t + \Delta t) - Y(t)$ 。
- 2) 增量 $\Delta Y(t)$ 服从伽玛分布, 即有 $\Delta Y(t) \sim \text{Gamma}(\Delta\eta(t), \omega)$, 其中 $\eta(t)$ 为 $\eta(0) = 0$ 的单调增函数且 $\Delta\eta(t) = \eta(t + \Delta t) - \eta(t)$ 。

此时, 性能演变增量 $\Delta Y(t)$ 的概率密度函数可表示为:

$$f(\Delta y(t)|\eta(t), \omega) = \frac{\omega^{\Delta\eta(t)}}{\Gamma(\Delta\eta(t))} (\Delta y(t))^{\Delta\eta(t)-1} \exp(-\omega\Delta y(t)) \quad (4-7)$$

根据式(4-3)给出的性能演变过程模型下机床故障时间的定义, 当 $Y(t)$ 服从伽玛过程时机床的故障时间 T 可以定义为 $T = \inf\{\tau \geq 0: y(\tau) \geq D\}$ 。根据伽玛过程模型的性质可以得到机床的可靠度函数为:

$$R(t|\eta(t), \omega) = \Pr(Y(t) < D | \eta(t), \omega) = \frac{\int_0^{\omega D} u^{\eta(t)-1} e^{-u} du}{\Gamma(\eta(t))} \quad (4-8)$$

伽玛过程模型主要用来描述性能演变轨迹为单调递增的性能演变过程。伽玛过程可看作复合泊松过程的近似过程，这与实际工程中机床的性能演变往往是由加工过程中切削力的作用以及外在冲击的影响等因素所造成的这一物理机理相符合，使得伽玛过程在性能演变过程建模的研究和应用中得到了广泛的关注。关于伽玛过程模型对性能演变过程建模的研究可参见 van Noortwijk 的综述文章^[71]。

(3) 逆高斯过程模型

当机床的性能演变过程 $\{Y(t), t \geq 0\}$ 服从均值函数为 $\Lambda(t)$ 、形状参数为 λ 的逆高斯过程时，其具有以下性质：

1) $Y(0) = 0$ 且 $Y(t)$ 具有独立增量 $\Delta Y(t) = Y(t + \Delta t) - Y(t)$ 。

2) 增量 $\Delta Y(t)$ 服从逆高斯分布，即有 $\Delta Y(t) \sim \text{IG}(\Delta\Lambda(t), \lambda\Delta\Lambda(t)^2)$ ，其中 $\Lambda(t)$ 为 $\Lambda(0) = 0$ 的单调增函数且 $\Delta\Lambda(t) = \Lambda(t + \Delta t) - \Lambda(t)$ 。

其中，均值函数 $\Lambda(t)$ 是对性能演变过程均值的描述，同时也可以看作性能演变过程的近似函数，当采用不同形式的均值函数时可以对不同轨迹形式的性能演变过程进行描述。形状参数 λ 是描述演变增量波动性的参数。

此时，性能演变过程可以描述为 $Y(t) \sim \text{IG}(\Lambda(t), \lambda\Lambda(t)^2)$ ， $Y(t)$ 和增量 $\Delta Y(t)$ 的概率密度函数可分别表示为：

$$f(y(t) | \Lambda(t), \lambda) = \sqrt{\frac{\lambda\Lambda(t)^2}{2\pi y(t)^3}} \exp\left(-\frac{\lambda(y(t) - \Lambda(t))^2}{2y(t)}\right) \quad (4-9)$$

$$f(\Delta y(t) | \Lambda(t), \lambda) = \sqrt{\frac{\lambda\Delta\Lambda(t)^2}{2\pi\Delta y(t)^3}} \exp\left(-\frac{\lambda(\Delta y(t) - \Delta\Lambda(t))^2}{2\Delta y(t)}\right) \quad (4-10)$$

根据式(4-3)给出的性能演变过程模型下机床故障时间的定义，结合逆高斯过程模型的性质可以得到机床的可靠度函数为：

$$\begin{aligned} R(t | \Lambda(t), \lambda) &= \Pr(Y(t) - Y(0) < D | \Lambda(t), \lambda) \\ &= \Phi\left(\sqrt{\frac{\lambda}{D}}(D - \Lambda(t))\right) + \exp(2\lambda\Lambda(t))\Phi\left(-\sqrt{\frac{\lambda}{D}}(D + \Lambda(t))\right) \end{aligned} \quad (4-11)$$

相对于维纳过程模型和伽玛过程模型，逆高斯过程模型属于较新的性能数据模型，它由 Wang 和 Xu^[159]于 2010 提出。逆高斯过程模型与伽玛过程模型类似，可看作复合泊松过程的近似过程，同时又与维纳过程具有逆变换的关系。这使得

逆高斯过程模型具有伽玛过程物理意义明确且对单调递增型性能演变过程建模的能力，同时兼顾了维纳过程模型参数意义清晰且随机效应和协变量引入方便等特性。近年来，逆高斯过程用于性能演变建模、数据分析、实验设计和可靠性评估等方面的研究逐渐展开，其特性和优势不断被挖掘^[156, 160-162]。本文将以逆高斯过程模型为基础，对重型数控机床性能演变过程建模、性能检测数据分析和可靠性评估展开深入研究。

4.3.2 性能演变速率形式多样的性能演变过程模型

重型数控机床的性能演变过程多与机床内在的多种性能演变机理的作用（如松动、老化、变形、磨损等）相互关联，其表现出来的性能演变过程往往具有单调递增的特性，即关键性能指标的演变为不可逆的过程。与此同时，考虑重型数控机床的复杂性在多种演变机理的作用下，其产生的性能演变过程往往表现出多种多样的性能演变形式，就其性能演变速率而言可能存在恒定速率、单调递增、单调递减、浴盆曲线、反浴盆曲线等多种形式。因此，在研究重型数控机床性能演变过程建模时需要对这两方面的特性进行重点考虑。对于单调递增型的性能演变过程，可以采用伽玛过程模型和逆高斯过程模型来对其进行建模。而进一步考虑多种演变轨迹形式的建模时，逆高斯过程由于模型参数物理意义明确使得其更适合于重型数控机床性能演变过程的建模。此时，基于逆高斯过程模型研究多种性能演变速率形式下的性能演变过程模型成为本文着力突破的关键点。

当采用逆高斯过程来描述机床的性能演变过程时有 $Y(t) \sim \text{IG}(\Lambda(t), \lambda\Lambda(t)^2)$ ，性能演变过程的均值函数为 $\Lambda(t)$ 而方差函数为 $\Lambda(t)/\lambda$ 。为了描述重型数控机床性能演变的多种形式，本文在逆高斯过程均值函数 $\Lambda(t)$ 的基础上引入近似性能演变速率函数。当 $\Lambda(t)$ 对 t 可导时逆高斯过程的近似性能演变速率函数 $r(t)$ 定义为^[155]：

$$r(t) = \frac{\partial \Lambda(t)}{\partial t} \quad (4-12)$$

近似性能演变速率函数引入的出发点是对演变过程轨迹大体趋势的近似描述。由于机床的性能演变轨迹可以看做是无穷小区间上性能演变增量的叠加所形成，近似性能演变速率函数的引入正是对无穷小区间上性能演变增量的变化速率的描述：当 $r(t)$ 较大时意味着在时间增量区间 Δt 上的性能演变增量 $\Delta Y(t)$ 较大，反之则较小。与此同时， $r(t)$ 随时间的变化是对性能演变过程轨迹随时间变化趋势的宏观描述：根据对性能演变机理的认识可以通过整体性能演变速率的变化趋势（如恒定性能演变速率、单调性能演变速率、浴盆曲线形式性能演变速率等）的判定来为性能检测数据模型的构建提供支撑。本文在式(4-9)所示逆高斯过程模

型的基础上，通过研究不同形式的性能演变速率函数来构建针对不同演变轨迹形式的逆高斯过程模型。

(1) 恒定速率的逆高斯过程模型

恒定性能演变速率（恒定速率）的逆高斯过程模型对应着机床的性能演变以稳定的趋势逐渐增加的性能演变过程，如图 4-1 所示。

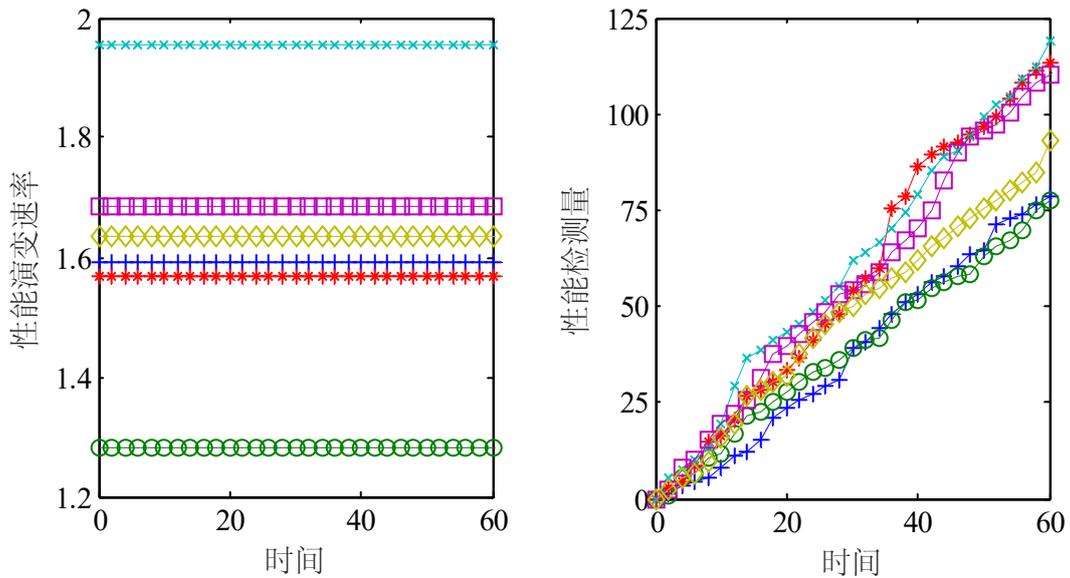


图 4-1 恒定性能演变速率的性能演变过程示例

恒定速率情形下的性能演变速率函数及其对应的性能演变均值函数分别为：

$$r_c(t) = \mu, \mu > 0 \tag{4-13}$$

$$\Lambda_c(t) = \int \mu dt = \mu t \tag{4-14}$$

在此基础上结合式(4-9)和(4-10)所示的一般化逆高斯过程模型的概率密度函数和机床可靠度函数可以得到：

$$f_c(y(t) | \mu, \lambda) = \sqrt{\frac{\lambda(\mu t)^2}{2\pi y(t)^3}} \exp\left(-\frac{\lambda(y(t) - \mu t)^2}{2y(t)}\right) \tag{4-15}$$

$$R_c(t | \mu, \lambda) = \Phi\left(\sqrt{\frac{\lambda}{D}}(D - \mu t)\right) + \exp(2\lambda\mu t) \Phi\left(-\sqrt{\frac{\lambda}{D}}(D + \mu t)\right) \tag{4-16}$$

(2) 单调速率的逆高斯过程模型

单调性能演变速率的逆高斯过程模型，根据性能演变速率的单调递增（递减），对应着机床的性能演变随着时间的增加而加剧（缓和）的过程，如图 4-2 所示。

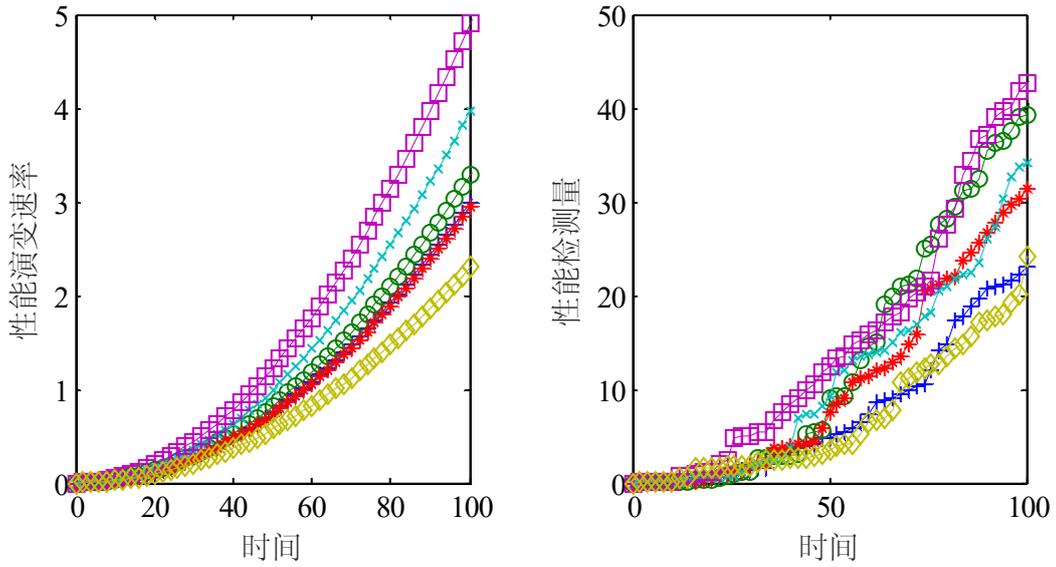


图 4-2 单调性能演变速率的性能演变过程示例

单调速率情形下的性能演变速率函数及其对应的性能演变均值函数分别为：

$$r_M(t) = \frac{\beta}{\eta} \left(\frac{t}{\eta} \right)^{\beta-1}, \beta > 0, \eta > 0 \quad (4-17)$$

$$\Lambda_M(t) = \int r_M(t) dt = \left(\frac{t}{\eta} \right)^\beta \quad (4-18)$$

式中， β 为性能演变速率函数的形状参数， η 为尺度参数；单调速率的形式由形状参数 β 所决定：当 $0 < \beta < 1$ 时， $r_M(t)$ 随着时间的增长而呈逐渐减小的趋势，即对应为单调递减型的速率函数；当 $\beta > 1$ 时， $r_M(t)$ 为单调递增型的速率函数；当 $\beta = 1$ 时， $r_M(t)$ 变为式(4-13)所示的恒定速率函数且有 $r_M(t) = r_C(t) = 1/\eta$ 。

对于具有单调速率的模型 $Y_M(t) \sim \text{IG}\left(\left(t/\eta\right)^\beta, \lambda\left(t/\eta\right)^{2\beta}\right)$ ，其对应的概率密度函数和机床的可靠度函数分别为：

$$f_M(y(t)|\eta, \beta, \lambda) = \sqrt{\frac{\lambda(t/\eta)^{2\beta}}{2\pi y(t)^3}} \exp\left(-\frac{\lambda(y(t) - (t/\eta)^\beta)^2}{2y(t)}\right) \quad (4-19)$$

$$R_M(t|\eta, \beta, \lambda) = \Phi\left(\sqrt{\frac{\lambda}{D}}\left(D - \left(\frac{t}{\eta}\right)^\beta\right)\right) + \exp\left(2\lambda\left(\frac{t}{\eta}\right)^\beta\right) \Phi\left(-\sqrt{\frac{\lambda}{D}}\left(D + \left(\frac{t}{\eta}\right)^\beta\right)\right) \quad (4-20)$$

(3) S 型速率的逆高斯过程模型

S 型性能演变速率的逆高斯过程模型主要是用来描述演变机理较为复杂的性

能演变过程，如图 4-3 所示。该类性能演变过程包含了以下阶段：在机床的使用初期，由于制造和装配缺陷导致的性能波动或劣化的演变过程；随着机床的使用磨合，性能变化逐渐缓和并稳定的演变过程；以及机床临近故障时，性能演变过程再次劣化直至发生故障的演变过程。

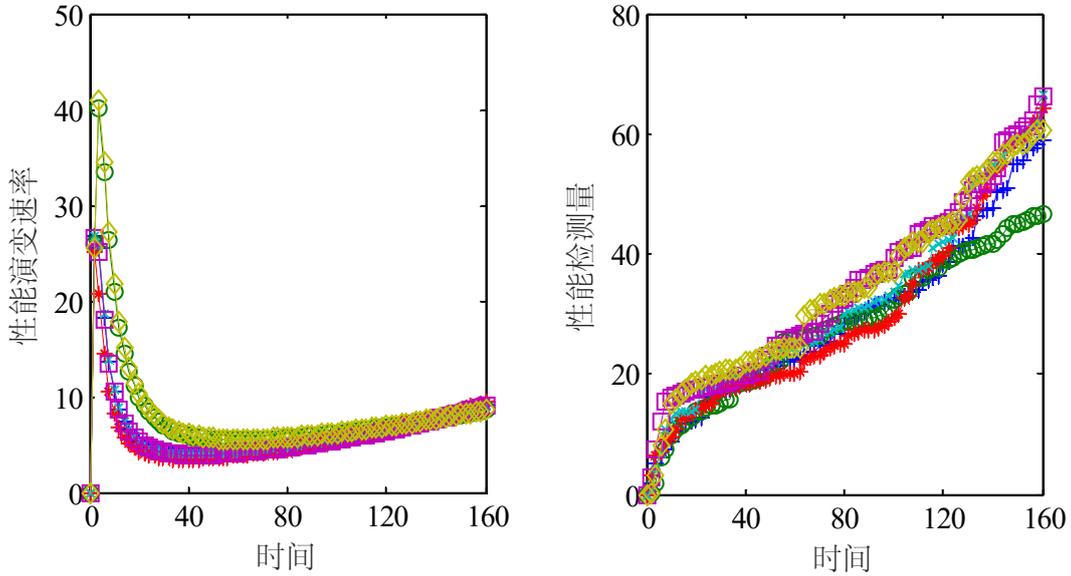


图 4-3 S 型性能演变速率的性能演变过程示例

S 型速率情形下的性能演变速率函数及其对应的性能演变均值函数分别为：

$$r_s(t) = \left(\alpha + \omega \left(\frac{t}{\nu} \right)^{-2} \right) \exp \left(\alpha \left(\frac{t}{\nu} \right) - \omega \left(\frac{t}{\nu} \right)^{-1} \right), \alpha > 0, \omega > 0, \nu > 0 \quad (4-21)$$

$$\Lambda_s(t) = \nu \exp \left(\alpha \left(\frac{t}{\nu} \right) - \omega \left(\frac{t}{\nu} \right)^{-1} \right) \quad (4-22)$$

式中， α 为形状参数，当 $0 < \alpha < 0.25$ 时 $r_s(t)$ 为 S 型的速率函数；当 $\alpha \geq 0.25$ 时 $r_s(t)$ 为单调递增的速率函数；参数 ω 和 ν 为尺度参数，当 $r_s(t)$ 为 S 型的速率函数时， ω 影响 S 型速率曲线初期上升和下降部分的分散程度且 $0 < \omega < 1$ ， ν 则影响 S 型速率曲线整体的分散程度。

对于具有 S 型速率的模型 $Y_s(t) \sim \text{IG}(\Lambda_s(t), \lambda \Lambda_s(t)^2)$ ，其对应的概率密度函数和机床的可靠度函数分别为：

$$f_s(y(t) | \alpha, \omega, \nu, \lambda) = \sqrt{\frac{\lambda \Lambda_s(t)^2}{2\pi y^3}} \exp \left(-\frac{\lambda (y(t) - \Lambda_s(t))^2}{2y(t)} \right) \quad (4-23)$$

$$R_s(t|\alpha, \omega, \nu, \lambda) = \Phi\left(\sqrt{\frac{\lambda}{D}}(D - \Lambda_s(t))\right) + \exp(2\lambda\Lambda_s(t))\Phi\left(-\sqrt{\frac{\lambda}{D}}(D + \Lambda_s(t))\right) \quad (4-24)$$

式中, $\Lambda_s(t)$ 为式(4-22)所示的性能演变均值函数。

4.3.3 考虑个体差异性和性能波动性的性能演变过程模型

在实际工程中, 同型号同批次重型数控机床虽然在结构和功能方面具有共同的特点, 但是由于加工、装配和使用环节中诸多因素的影响(如零部件、材料、工艺、环境条件和工作应力的差别), 机床实际表现出来的性能往往存在一定的个体差异性。这意味着即使是同型号同批次的机床, 在所表现出来的性能演变过程也存在各自的特性。特别是对于大重型数控机床, 产品的个体差异性表现得尤为突出: 一方面可表现为同一总体下不同机床具有各自独特的性能演变速率, 另一方面可表现为同一总体下不同机床在各自的时间域内性能演变增量具有各自独特的波动性。因此, 在研究重型数控机床的性能演变过程建模时需要将机床所表现出来的个体差异性和性能波动性进行研究。

以上所建立的性能演变过程模型都是针对机床总体的模型, 其中并没有对机床各个个体所具有的性能演变特性进行考虑。对于同一总体中不同个体所具有的特性建模往往采用随机效应模型(Random Effect)^[84, 153, 158, 162], 即在总体模型中的某一与个体差异性相关的模型参数中引入随机变量, 使得总体上该模型参数服从某一概率分布, 而每个个体所对应的模型参数则是这一概率分布的一个样本实现。将这样的随机效应模型引入到性能演变过程模型中, 可以对机床性能演变过程的个体差异性进行描述。

当采用逆高斯过程来描述机床的性能演变过程时有 $Y(t) \sim \text{IG}(\Lambda(t), \lambda\Lambda(t)^2)$, 其中性能演变过程的均值函数为 $\Lambda(t)$, 方差函数为 $\Lambda(t)/\lambda$ 。对于均值函数的选择可以根据性能演变轨迹的形式选择式(4-14)、(4-18)或(4-22)所示的形式。由于均值函数同时影响着性能演变过程模型的均值和方差, 而尺度参数只影响性能演变过程模型的方差, 可以将随机效应模型引入到均值函数中。这样一方面可以实现对机床性能演变个体差异性的建模描述, 另一方面可以同时兼顾机床性能波动性的建模表征。

(1) 考虑个体差异性和性能波动性的恒定速率逆高斯过程模型

对于恒定速率的逆高斯过程模型 $Y(t) \sim \text{IG}(\mu t, \lambda\mu^2 t^2)$, 当引入随机效应模型时可令参数 μ 服从某一概率分布, 如伽玛分布、对数正态分布、威布尔分布等。本文以伽玛分布为例来对建模过程进行描述, μ 服从伽玛分布且其概率分布为:

$$g_{\mu}(\mu|\delta_{\mu},\gamma_{\mu})=\frac{\gamma_{\mu}^{\delta_{\mu}}\mu^{\delta_{\mu}-1}}{\int_0^{\infty}x^{\delta_{\mu}-1}e^{-x}dx}\exp(-\gamma_{\mu}\mu),\delta_{\mu}>0,\gamma_{\mu}>0 \quad (4-25)$$

此时, 设某一机床的总体中包含 n 个同型号同批次的机床, 当考虑机床个体差异性和性能波动性时各个个体的性能演变过程可以描述为 $Y_{CE}(t) \sim \text{IG}(\mu_i t, \lambda(\mu_i t)^2)$ 且有 $\mu_i \sim \text{Gamma}(\delta_{\mu}, \gamma_{\mu})$ ($i=1, \dots, n$)。在该模型下, 对于总体中各个个体的性能演变过程的概率密度函数和可靠度函数分别如式(4-15)和(4-16)所示, 其中模型参数 μ_i 为各个个体自身性能演变特性所对应的参数。对于样本总体而言, 其性能演变过程的概率密度函数和机床的可靠度函数可分别表示为:

$$f_{CE}(y(t)|\delta_{\mu},\gamma_{\mu},\lambda)=\int_{\mu>0}f_C(y(t)|\mu,\lambda)g_{\mu}(\mu|\delta_{\mu},\gamma_{\mu})d\mu \quad (4-26)$$

$$R_{CE}(t|\delta_{\mu},\gamma_{\mu},\lambda)=\int_{\mu>0}R_C(t|\mu,\lambda)g_{\mu}(\mu|\delta_{\mu},\gamma_{\mu})d\mu \quad (4-27)$$

(2) 考虑个体差异性和性能波动性的单调速率逆高斯过程模型

对于单调速率的逆高斯过程模型 $Y_M(t) \sim \text{IG}((t/\eta)^{\beta}, \lambda(t/\eta)^{2\beta})$, β 决定着性能演变速率的形式并与机床性能演变机理相关, 而 η 只影响某一演变形式下性能演变速率的大小。对于性能演变差异性的建模可令参数 η 服从某一概率分布, 本文以伽玛分布为例来对建模过程进行描述。此时, 对于样本量为 n 的总体中各个体的性能演变过程为 $Y_{ME}(t) \sim \text{IG}((t/\eta_i)^{\beta}, \lambda(t/\eta_i)^{2\beta})$ 且 $\eta_i \sim \text{Gamma}(\delta_{\eta}, \gamma_{\eta})$ ($i=1, \dots, n$)。在该模型下, 总体中各个体的性能演变过程的概率密度函数和可靠度函数分别如式(4-19)和(4-20)所示, 且其中模型参数 η_i 为各个个体自身性能演变特性所对应的参数。对于样本总体而言, 其性能演变过程的概率密度函数和机床的可靠度函数可分别表示为:

$$f_{ME}(y(t)|\delta_{\eta},\gamma_{\eta},\beta,\lambda)=\int_{\eta>0}f_M(y(t)|\eta,\beta,\lambda)g_{\eta}(\eta|\delta_{\eta},\gamma_{\eta})d\eta \quad (4-28)$$

$$R_{ME}(t|\delta_{\eta},\gamma_{\eta},\beta,\lambda)=\int_{\eta>0}R_M(t|\eta,\beta,\lambda)g_{\eta}(\eta|\delta_{\eta},\gamma_{\eta})d\eta \quad (4-29)$$

(3) 考虑个体差异性和性能波动性的 S 型速率逆高斯过程模型

对于 S 型速率的逆高斯过程模型 $Y_S(t) \sim \text{IG}(\Lambda_S(t), \lambda\Lambda_S(t)^2)$, α 为形状参数, ω 为局部尺度参数, ν 为全局尺度参数。可将随机影响模型引入参数 ν , 来对个体差异性进行建模。此时, 对于样本量为 n 的机床总体中, 当考虑机床个体差异性和性能波动性时各个体的性能演变过程可以描述为 $Y_{SE}(t) \sim \text{IG}(\Lambda_{Si}(t), \lambda\Lambda_{Si}(t)^2)$, $\Lambda_{Si}(t) = \nu_i \exp(\alpha(t/\nu_i) - \omega(t/\nu_i)^{-1})$ 且 $\nu_i \sim \text{Gamma}(\delta_{\nu}, \gamma_{\nu})$ ($i=1, \dots, n$)。在该模型下, 总体中各个体的性能演变过程的概率密度函数和可靠度函数分别如式(4-23)和(4-24)所示, 且其中模型参数 η_i 为各个个体自身性能演变特性所对应的参数。对于样

本总体而言，其性能演变过程的概率密度函数和机床的可靠度函数可分别表示为：

$$f_{SE}(y(t)|\alpha, \omega, \delta_v, \gamma_v, \lambda) = \int_{v>0} f_S(y(t)|\alpha, \omega, v, \lambda) g_v(v|\delta_v, \gamma_v) dv \quad (4-30)$$

$$R_{SE}(t|\alpha, \omega, \delta_v, \gamma_v, \lambda) = \int_{v>0} R_S(t|\alpha, \omega, v, \lambda) g_v(v|\delta_v, \gamma_v) dv \quad (4-31)$$

值得指出的是随机效应模型的引入是解决机床性能演变过程个体差异性和性能波动性建模的主要方法，上述建模过程是对其具体应用和实施的示例性描述。在实际应用过程中，需要结合基础性能演变过程模型（如本文中的逆高斯过程模型）中各模型参数的物理意义选择随机效应模型引入的切入点。对于随机效应模型中概率分布的选择，一方面要考虑参数取值范围的限制，另一方面要考虑概率分布的特性以及模型求解的难易程度。

4.4 基于性能检测数据的重型数控机床可靠性评估

在上文性能演变过程模型建立的基础上，当获得重型数控机床的性能检测数据后要对机床的可靠性进行评估，需要着重解决模型参数估计与可靠性指标求解这两个关键问题。本文着重研究基于贝叶斯方法的性能检测数据分析与可靠性评估。首先研究贝叶斯方法下重型数控机床性能检测数据分析与可靠性评估的基本框架，然后在此基础上构建基于贝叶斯方法的性能检测数据分析的数学表达，最后研究参数估计和指标求解的算法，以实现主机厂与用户厂性能检测数据的融合分析与机床可靠性的评估。

4.4.1 基于贝叶斯方法的性能检测数据分析基本框架

贝叶斯方法在重型数控机床性能检测数据分析中具有两大优势：一是贝叶斯方法对数据和信息的融合能力，使得主机厂和用户厂性能检测数据的融合分析成为可能；二是贝叶斯方法对不确定性的处理能力，使得性能检测数据分析和可靠性评估结果的表征得到保障。这两点也是构建贝叶斯性能检测数据分析与可靠性评估基本框架的立足点。据此，本文针对重型数控机床性能检测数据分析的特性，结合上文所建立的性能演变过程模型，构建如图 4-4 所示的贝叶斯性能检测数据分析和可靠性评估的基本框架。

该框架以层次贝叶斯方法为核心、以主机厂和用户厂性能检测数据更新融合为要点，涵盖三大部分：先验分布的获取、似然函数的表达和后验分布的求解。基于这三大部分该框架的主线可描述为：采用先主机厂后用户厂的性能检测数据分析策略，以及主机厂数据分析所得的后验分布作为用户厂数据分析的先验分布的更新融合策略；通过层次贝叶斯方法将先验分布和似然函数表示成后验分布的

形式，然后通过对后验分布的抽样和基于数值积分方法的分析，完成性能检测数据的分析和机床可靠性的评估。

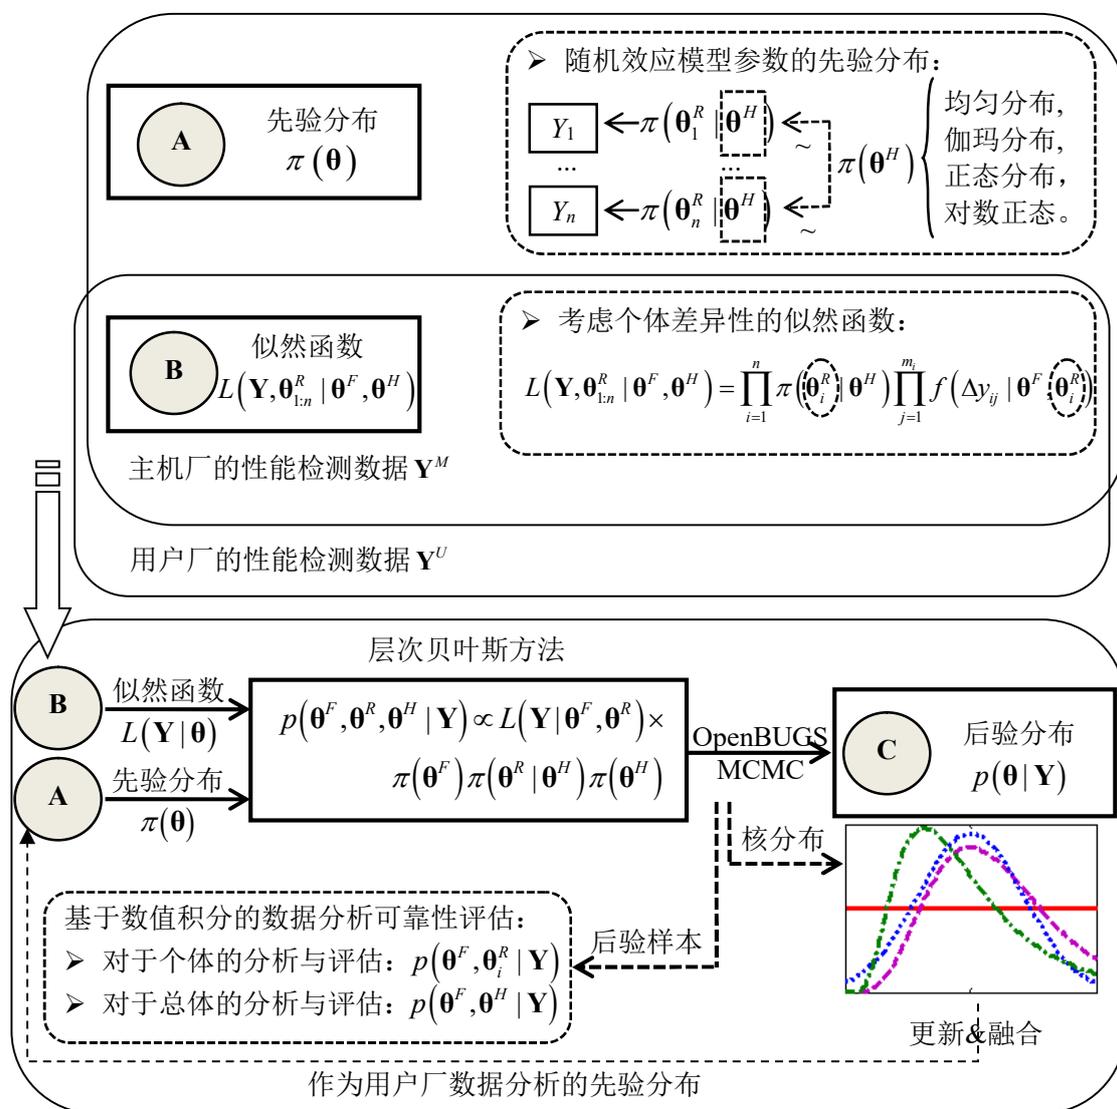


图 4-4 基于贝叶斯方法的性能检测数据分析和可靠性评估基本框架

对于先验分布的获取，该框架根据所分析数据来源的不同，分为两大类先验分布的获取方法。对于主机厂性能检测数据分析时的先验分布，采用主观信息量化和层次先验分布获取的方法；对于用户厂性能检测数据分析时的先验分布，采用直接从主机厂性能退化分析所得后验分布转化的方法。

在用户厂性能检测数据分析时，根据模型参数性质的不同将模型参数分为三类：没有考虑随机效应的参数 θ^F （固定参数），考虑了随机效应的参数 θ^R （随机参数），以及参数 θ^R 对应概率分布模型中的参数 θ^H （超参数）。固定参数先验分布的获取，主要应用主观信息和历史经验信息量化的方法，以此获取有信息的先验

分布，或者采用诸如均匀分布等无信息的先验分布。这类先验分布获取的方法已在第三章进行了描述，此处不再赘述。对于随机参数和超参数先验分布的获取，主要采用层次先验分布的方法，主要包括以下方面。对于总体中的每个个体都有 $\pi(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^H)$ ，该概率分布是随机效应模型引入至参数 $\boldsymbol{\theta}_i^R$ 时所选用的概率分布，如上文所采用的伽玛分布，而概率分布的参数 $\boldsymbol{\theta}^H$ 即为超参数。如图 4-4 所示，总体中所有个体的 $\pi(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^H)$ 分布形式相同且共享了超参数 $\boldsymbol{\theta}^H$ 。此时，先验分布的获取首先采用类似于固定参数先验分布获取的方法，获取超参数的先验分布；然后利用超参数与随机参数之间的条件概率关系，获取超参数和随机参数的联合先验分布 $\pi(\boldsymbol{\theta}^R | \boldsymbol{\theta}^H)\pi(\boldsymbol{\theta}^H)$ 。这样的层次先验分布，一方面符合用来描述机床个体差异性的随机影响模型的结构，另一方面可以通过各个体所共享的超参数来构建个体间信息融合的通道。

对于似然函数的表达，其关键在于通过似然函数将性能检测数据所包含的信息有效地表述成模型参数的函数形式，其中又以随机影响参数的引入和表达为关键点。对于后验分布的求解，其关键在于基于层次贝叶斯方法的性能演变过程模型参数后验分布的构建、基于 MCMC 方法的后验分布的抽样以及基于数值积分的性能演变预计与可靠性评估。

下面将分别对似然函数的表达和后验分布的求解进行详细描述。

4.4.2 性能检测数据分析的数学表达

重型数控机床的性能检测数据包括来自于主机厂和用户厂的性能检测数据 \mathbf{Y}^M 和 \mathbf{Y}^U ，这两种来源的数据虽在数学表述上可以采用同样的方式。在 n 台机床所组成的总体中，第 i 台机床在第 j 个观测时间点 t_{ij} 的性能检测量为 $y(t_{ij})$ 且有 $i=1, \dots, n, j=1, \dots, m_i$ 。令 $\Delta y(t_{ij}) = y(t_{ij}) - y(t_{i,j-1})$ 表示性能演变增量且有 $y(t_{i0}) = 0$ 。根据图 4-4 所示的贝叶斯性能检测数据分析的基本框架，性能检测数据 \mathbf{Y}^M 和 \mathbf{Y}^U 统一记为 \mathbf{Y} ，其似然函数可以描述为：

$$L(\mathbf{Y}, \boldsymbol{\theta}_{1:n}^R | \boldsymbol{\theta}^F, \boldsymbol{\theta}^H) = \prod_{i=1}^n \pi(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^H) \prod_{j=1}^{m_i} f(\Delta y_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) \quad (4-32)$$

式中， $\boldsymbol{\theta}^F$ 为性能演变过程模型中的固定参数， $\boldsymbol{\theta}_{1:n}^R$ 为所有个体对应的随机参数的集合有 $\boldsymbol{\theta}_{1:n}^R = \{\boldsymbol{\theta}_i^R, i=1, \dots, n\}$ ， $\boldsymbol{\theta}^H$ 为超参数； $\pi(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^H)$ 为随机参数所对应的概率分布， $f(\Delta y_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R)$ 为性能演变过程模型下性能演变增量对应的概率分布。

在此基础上可以得到各性能演变过程模型下 \mathbf{Y} 的具体表达式。

(1) 恒定速率逆高斯过程模型下 \mathbf{Y} 的似然函数

$$\begin{aligned}
 L(\mathbf{Y}, \boldsymbol{\mu} | \delta_\mu, \gamma_\mu, \lambda) &= \prod_{i=1}^n g_\mu(\mu_i | \delta_\mu, \gamma_\mu) \prod_{j=2}^{m_i} f_C(\Delta y_{ij} | \mu_i, \lambda) \\
 &= \prod_{i=1}^n \frac{\gamma_\mu^{\delta_\mu} \mu_i^{\delta_\mu - 1} e^{-\gamma_\mu \mu_i}}{\int_0^\infty x^{\delta_\mu - 1} e^{-x} dx} \prod_{j=2}^{m_i} \sqrt{\frac{\lambda (\Delta \Lambda_{ij}^C)^2}{2\pi (\Delta y_{ij})^3}} \exp\left(-\frac{\lambda (\Delta y_{ij} - \Delta \Lambda_{ij}^C)^2}{2\Delta y_{ij}}\right) \quad (4-33)
 \end{aligned}$$

式中, $\Delta \Lambda_{ij}^C = \mu_i t_{ij} - \mu_i t_{i,j-1}$, $\boldsymbol{\mu} = (\mu_1, \dots, \mu_n)$ 包含了所有个体的随机参数。

(2) 单调速率逆高斯过程模型下 \mathbf{Y} 的似然函数

$$\begin{aligned}
 L(\mathbf{Y}, \boldsymbol{\eta} | \delta_\eta, \gamma_\eta, \beta, \lambda) &= \prod_{i=1}^n g_\eta(\eta_i | \delta_\eta, \gamma_\eta) \prod_{j=2}^{m_i} f_M(\Delta y_{ij} | \eta_i, \beta, \lambda) \\
 &= \prod_{i=1}^n \frac{\gamma_\eta^{\delta_\eta} \eta_i^{\delta_\eta - 1} e^{-\gamma_\eta \eta_i}}{\int_0^\infty x^{\delta_\eta - 1} e^{-x} dx} \prod_{j=2}^{m_i} \sqrt{\frac{\lambda (\Delta \Lambda_{ij}^M)^2}{2\pi (\Delta y_{ij})^3}} \exp\left(-\frac{\lambda (\Delta y_{ij} - \Delta \Lambda_{ij}^M)^2}{2\Delta y_{ij}}\right) \quad (4-34)
 \end{aligned}$$

式中, $\Delta \Lambda_{ij}^M = (t_{ij}/\eta)^{\beta_i} - (t_{i,j-1}/\eta)^{\beta_i}$, $\boldsymbol{\eta} = (\eta_1, \dots, \eta_n)$ 包含了所有个体的随机参数。

(3) S 型速率逆高斯过程模型下 \mathbf{Y} 的似然函数

$$\begin{aligned}
 L(\mathbf{Y}, \mathbf{v} | \alpha, \omega, \delta_v, \gamma_v, \lambda) &= \prod_{i=1}^n g_v(v_i | \delta_v, \gamma_v) \prod_{j=2}^{m_i} f_S(\Delta y_{ij} | \alpha, \omega, v_i, \lambda) \\
 &= \prod_{i=1}^n \frac{\gamma_v^{\delta_v} v_i^{\delta_v - 1} e^{-\gamma_v v_i}}{\int_0^\infty x^{\delta_v - 1} e^{-x} dx} \prod_{j=2}^{m_i} \sqrt{\frac{\lambda (\Delta \Lambda_{ij}^S)^2}{2\pi (\Delta y_{ij})^3}} \exp\left(-\frac{\lambda (\Delta y_{ij} - \Delta \Lambda_{ij}^S)^2}{2\Delta y_{ij}}\right) \quad (4-35)
 \end{aligned}$$

式中, $\Delta \Lambda_{ij}^S = \Lambda_S(t_{ij}) - \Lambda_S(t_{i,j-1})$, $\mathbf{v} = (v_1, \dots, v_n)$ 包含了所有个体的随机参数。

从以上不同性能演变过程模型下性能检测数据 \mathbf{Y} 的似然函数可知: 性能检测数据的似然函数都是利用随机过程模型中独立增量的性质以及其所服从概率分布的概率密度函数来构建的。当考虑机床个体差异性时, 每个个体的随机参数是通过其对应的概率分布的概率密度函数嵌入到似然函数中, 从而实现性能检测数据与随机参数及其超参数的信息关联。

当采用图 4-4 所示的先验分布获取方法得到模型参数的先验分布之后, 应用层次贝叶斯方法将先验分布与似然函数进行融合即可得到模型参数的后验分布。分别用 $\pi(\boldsymbol{\theta}^F)$ 和 $\pi(\boldsymbol{\theta}^H)$ 表示固定参数和超参数的先验分布, 结合式(4-32)所示的一般化的似然函数, 可得到模型参数的后验分布为:

$$p(\boldsymbol{\theta} | \mathbf{Y}) \propto \pi(\boldsymbol{\theta}^F) \pi(\boldsymbol{\theta}^H) \prod_{i=1}^n \pi(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^H) \prod_{j=1}^{m_i} f(\Delta y_{ij} | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) \quad (4-36)$$

式中, $\boldsymbol{\theta}$ 包含性能演变过程模型的所有参数。

分别将具体模型下的先验分布以及式(4-33)至(4-35)所示的似然函数代入上式

即可得到不同模型下模型参数后验分布的表达式。下面以恒定速率逆高斯过程模型为例，对模型参数后验分布的构建进行示例描述。

对于性能检测数据 $\mathbf{Y} = \{y(t_{ij}), i=1, \dots, n, j=1, \dots, m_i\}$ ，在恒定速率性能演变过程模型 $Y_C(t) \sim \text{IG}(\mu_i t, \lambda(\mu_i t)^2)$ ， $\mu_i \sim \text{Gamma}(\delta_\mu, \gamma_\mu)$ 下，当获得参数 λ ， δ_μ 和 γ_μ 的先验分布为 $\lambda \sim \text{Lognormal}(\mu_\lambda, \sigma_\lambda^2)$ ， $\delta_\mu \sim \text{Gamma}(a_\delta, b_\delta)$ 和 $\gamma_\mu \sim \text{Gamma}(a_\gamma, b_\gamma)$ 时，结合式(4-33)所示的性能检测数据 \mathbf{Y} 的似然函数，应用式(4-36)所示的基于层次贝叶斯方法的后验分布获取方法，可以得到融合先验信息和性能检测数据的模型参数后验分布为：

$$p(\boldsymbol{\mu}, \delta_\mu, \gamma_\mu, \lambda | \mathbf{Y}) \propto \pi(\delta_\mu) \pi(\gamma_\mu) \pi(\lambda) L(\mathbf{Y}, \boldsymbol{\mu} | \delta_\mu, \gamma_\mu, \lambda) \\ = \frac{b_\delta^{a_\delta} \delta_\mu^{a_\delta-1} e^{-b_\delta \delta_\mu}}{\int_0^\infty x^{a_\delta-1} e^{-x} dx} \times \frac{b_\gamma^{a_\gamma} \gamma_\mu^{a_\gamma-1} e^{-b_\gamma \gamma_\mu}}{\int_0^\infty x^{a_\gamma-1} e^{-x} dx} \times \frac{e^{-(\ln \lambda - \mu_\lambda)^2 \sigma_\lambda^2 / 2}}{\lambda \sigma_\lambda \sqrt{2\pi}} \times \quad (4-37) \\ \prod_{i=1}^n \frac{\gamma_\mu^{\delta_\mu} \mu_i^{\delta_\mu-1} e^{-\gamma_\mu \mu_i}}{\int_0^\infty x^{\delta_\mu-1} e^{-x} dx} \prod_{j=2}^{m_i} \sqrt{\frac{\lambda (\Delta \Lambda_{ij}^C)^2}{2\pi (\Delta y_{ij})^3}} \exp\left(-\frac{\lambda (\Delta y_{ij} - \Delta \Lambda_{ij}^C)^2}{2\Delta y_{ij}}\right)$$

式中， $\boldsymbol{\mu} = (\mu_1, \dots, \mu_n)$ ， $\Delta y_{ij} = y(t_{ij}) - y(t_{i,j-1})$ 和 $\Delta \Lambda_{ij}^C = \mu_i t_{ij} - \mu_i t_{i,j-1}$ 。

上式是模型参数 $\{\boldsymbol{\mu}, \delta_\mu, \gamma_\mu, \lambda\}$ 的联合后验分布，在实际计算的时候可以将与模型参数不相关的部分去掉，得到后验分布的核分布部分以提高后验分布抽样的计算效率。对于上式所示的联合后验分布可以进一步简化得到：

$$p(\boldsymbol{\mu}, \delta_\mu, \gamma_\mu, \lambda | \mathbf{Y}) \propto \pi(\delta_\mu) \pi(\gamma_\mu) \pi(\lambda) L(\mathbf{Y}, \boldsymbol{\mu} | \delta_\mu, \gamma_\mu, \lambda) \\ \propto \delta_\mu^{a_\delta-1} e^{-b_\delta \delta_\mu} \times \gamma_\mu^{a_\gamma-1} e^{-b_\gamma \gamma_\mu} \times \lambda^{-1} e^{-(\ln \lambda - \mu_\lambda)^2 \sigma_\lambda^2 / 2} \times \quad (4-38) \\ \prod_{i=1}^n \frac{\gamma_\mu^{\delta_\mu} \mu_i^{\delta_\mu-1} e^{-\gamma_\mu \mu_i}}{\int_0^\infty x^{\delta_\mu-1} e^{-x} dx} \prod_{j=2}^{m_i} \sqrt{\lambda (\Delta \Lambda_{ij}^C)^2} \exp\left(-\frac{\lambda (\Delta y_{ij} - \Delta \Lambda_{ij}^C)^2}{2\Delta y_{ij}}\right)$$

这些后验分布中不仅包括了固定参数和超参数的后验分布，同时也包括了随机参数的后验分布。在基于模型参数后验分布样本的性能检测数据分析与可靠性评估中，针对总体的分析与评估主要是利用固定参数和超参数的后验样本，而对于个体的分析与评估主要是利用固定参数和各个个体对应随机参数的后验样本。

4.4.3 融合主机厂与用户厂性能检测数据的贝叶斯可靠性评估

在性能检测数据建模与基于贝叶斯评估方法的分析基础上，根据图 4-4 所示的主机厂与用户厂性能检测数据逐次分析融合的策略得到模型参数的联合后验分布，并将其实现过程描述为：

$$\begin{aligned}
 p_1(\boldsymbol{\theta} | \mathbf{Y}^M) &\propto \pi(\boldsymbol{\theta}^F) \pi(\boldsymbol{\theta}^H) \prod_{i=1}^n \pi(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^H) \prod_{j=1}^{m_i} f(\Delta y_{ij}^M | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R) \\
 p_{\Pi}(\boldsymbol{\theta} | \mathbf{Y}^U, \mathbf{Y}^M) &\propto p_1(\boldsymbol{\theta}^F, \boldsymbol{\theta}^H | \mathbf{Y}^M) \prod_{i=1}^n \pi(\boldsymbol{\theta}_i^R | \boldsymbol{\theta}^H) \prod_{j=1}^{m_i} f(\Delta y_{ij}^U | \boldsymbol{\theta}^F, \boldsymbol{\theta}_i^R)
 \end{aligned} \tag{4-39}$$

式中， \mathbf{Y}^M 为主机厂的性能检测数据， $\pi(\boldsymbol{\theta}^F)$ 和 $\pi(\boldsymbol{\theta}^H)$ 是根据专家经验数据和历史数据所获得的模型先验分布， $p_1(\boldsymbol{\theta} | \mathbf{Y}^M)$ 是融合先验信息与主机厂性能检测数据得到的模型参数后验分布； \mathbf{Y}^U 为用户厂的性能检测数据， $p_{\Pi}(\boldsymbol{\theta} | \mathbf{Y}^U, \mathbf{Y}^M)$ 是融合了先验信息、主机厂和用户厂性能检测数据的模型参数后验分布。

式(4-39)所示的融合方法是考虑了性能检测数据获取的时间先后顺序，也是为了清楚地描述主机厂与用户厂性能检测数据逐次分析的策略所构建的。在求解后验分布 $p_{\Pi}(\boldsymbol{\theta} | \mathbf{Y}^U, \mathbf{Y}^M)$ 时可以将式(4-39)重新表述为：

$$p_{\Pi}(\boldsymbol{\theta} | \mathbf{Y}^U, \mathbf{Y}^M) \propto \pi(\boldsymbol{\theta}^F) \pi(\boldsymbol{\theta}^H) L(\mathbf{Y}^U, \mathbf{Y}^M, \boldsymbol{\theta}_{1:n}^R | \boldsymbol{\theta}^F, \boldsymbol{\theta}^H) \tag{4-40}$$

基于上式可以获得模型参数后验分布 $p_{\Pi}(\boldsymbol{\theta} | \mathbf{Y}^U, \mathbf{Y}^M)$ 的核分布，并在此基础上应用 MCMC 方法来对后验分布抽样得到后验分布的样本，进一步可以开展基于后验样本的性能检测数据分析和可靠性评估。

当获得模型参数的后验分布之后，对于机床的性能演变预测和可靠性评估主要包括：机床在未来观测时间点性能演变变量的预测、机床在未来观测点可靠性的评估以及机床剩余寿命（Remaining Useful Life）的评估。而对于总体中考虑个体差异性的一组机床而言，性能演变变量的预测以及可靠性和剩余寿命的评估又可进一步分为针对机床个体的性能演变预测、可靠性评估和剩余寿命评估以及针对机床总体的相应指标和特征量的预测和评估。

令 t_{im_i} 和 t_{i,m_i+l} 分别为第 i 个机床当前和未来的观测时间点， t_{im} 和 $t_{i,m+l}$ 分别为机床总体当前和未来的观测时间点。下面，根据图 4-4 所示的基本框架，结合 4.3 节中建立的性能检测数据模型及式(4-40)所示的模型参数后验分布，分别建立机床性能演变预测和可靠性评估的具体表达式。

1) 针对机床个体在未来观测时间点 t_{i,m_i+l} 的性能演变预测为：

$$f_A(y(t_{i,m_i+l}) | \mathbf{Y}^U, \mathbf{Y}^M) = \int_{\boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F} p_{\Pi}(\boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F | \mathbf{Y}^U, \mathbf{Y}^M) f_A(y(t_{i,m_i+l}) | \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F) d\boldsymbol{\theta}_i^R d\boldsymbol{\theta}^F \tag{4-41}$$

式中， A 代表 4.3.2 节中所建立的恒定速率、单调速率和 S 型速率模型，即 $f_A(y(t_{i,m_i+l}) | \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F)$ 分别对应于式(4-15)、(4-19)和(4-23)所示的概率密度函数，且其中随机效应模型引入的参数对应于 $\boldsymbol{\theta}_i^R$ ，其他参数则对应于 $\boldsymbol{\theta}^F$ 。

2) 针对机床个体在未来观测时间点 t_{i,m_i+l} 的可靠性评估为：

$$R_A(t_{i,m_i+l} | \mathbf{Y}^U, \mathbf{Y}^M) = \int_{\boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F} p_{\Pi}(\boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F | \mathbf{Y}^U, \mathbf{Y}^M) R_A(t_{i,m_i+l} | \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F) d\boldsymbol{\theta}_i^R d\boldsymbol{\theta}^F \quad (4-42)$$

式中, $R_A(t_{i,m_i+l} | \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F)$ 分别对应于式(4-16)、(4-20)和(4-24)所示的可靠度函数, 且其中随机效应模型引入的参数对应于 $\boldsymbol{\theta}_i^R$, 其他参数则对应于 $\boldsymbol{\theta}^F$ 。

3) 针对机床个体剩余寿命的评估为:

$$T_i^{RUL} = \inf \left\{ r : y(t_{im_i} + r) > D \mid f_A(y(t_{im_i} + r) | \mathbf{Y}^U, \mathbf{Y}^M), y(t_{im_i}) < D \right\} \quad (4-43)$$

式中, $f_A(y(t_{i,m_i+l}) | \boldsymbol{\theta}_i^R, \boldsymbol{\theta}^F)$ 为式(4-41)所示的机床个体在时间点 t_{i,m_i+l} 性能演变量 $y(t_{i,m_i+l})$ 的概率密度函数。剩余寿命的评估需要借助于个体性能演变预测来开展, 通过采用从当前观测点 t_{im_i} 开始, 逐次获得序列观测点的性能演变预测值并将其与性能演变阈值对比, 以此判断该时间点机床是否故障, 从而获得剩余寿命的估计值。

4) 针对机床总体在未来观测时间点 t_{i,m_i+l} 的性能演变预测为:

$$f_A(y(t_{m_i+l}) | \mathbf{Y}^U, \mathbf{Y}^M) = \int_{\boldsymbol{\theta}^F, \boldsymbol{\theta}^H} p_{\Pi}(\boldsymbol{\theta}^F, \boldsymbol{\theta}^H | \mathbf{Y}^U, \mathbf{Y}^M) f_A(y(t_{m_i+l}) | \boldsymbol{\theta}^F, \boldsymbol{\theta}^H) d\boldsymbol{\theta}^F d\boldsymbol{\theta}^H \quad (4-44)$$

式中, $f_A(y(t_{m_i+l}) | \boldsymbol{\theta}^F, \boldsymbol{\theta}^H)$ 分别对应于式(4-26)、(4-28)和(4-30)所示的概率密度函数。

5) 针对机床总体在未来观测时间点 t_{m_i+l} 的可靠性评估为:

$$R_A(t_{m_i+l} | \mathbf{Y}^U, \mathbf{Y}^M) = \int_{\boldsymbol{\theta}^F, \boldsymbol{\theta}^H} p_{\Pi}(\boldsymbol{\theta}^F, \boldsymbol{\theta}^H | \mathbf{Y}^U, \mathbf{Y}^M) R_A(t_{m_i+l} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^H) d\boldsymbol{\theta}^F d\boldsymbol{\theta}^H \quad (4-45)$$

式中, $R_A(t_{m_i+l} | \boldsymbol{\theta}^F, \boldsymbol{\theta}^H)$ 分别对应于式(4-27)、(4-29)和(4-31)所示的可靠度函数。

6) 针对机床总体剩余寿命的评估为:

$$T^{RUL} = \inf \left\{ r : y(t_{im_i} + r) > D \mid f_A(y(t_{m_i+l} + r) | \mathbf{Y}^U, \mathbf{Y}^M), y(t_{im_i}) < D \right\} \quad (4-46)$$

式中, $f_A(y(t_{m_i+l} + r) | \mathbf{Y}^U, \mathbf{Y}^M)$ 为式(4-44)所示的机床总体在时间点 t_{m_i+l} 性能演变量 $y(t_{m_i+l})$ 的概率密度函数。与针对机床个体剩余寿命的评估类似, 针对总体的寿命评估需要借助于总体性能演变预测来展开, 通过逐次预测序列观测点的性能演变值并与性能演变阈值对比来获得机床性能演变轨迹的首次穿越时间 (发生故障的时间点), 从而获得机床的剩余寿命。

以上机床的性能演变预测、可靠性评估和剩余寿命评估, 针对个体和总体的主要区别在于所使用的性能演变的概率密度和可靠度函数不同。针对个体的预测与评估所采用的概率密度和可靠度函数是建立在固定参数和随机参数之上的, 而针对总体的预测和评估则是建立在固定参数和超参数之上的。

对于模型参数后验分布基于 MCMC 方法的抽样, 本文采用 OpenBUGS 软件

来实现。对于性能演变预测、可靠性评估以及剩余寿命评估的求解，本文在模型参数后验分布样本的基础上采用数值积分方法来实现。下面以恒定速率逆高斯过程模型为例来对后验分布的抽样、性能演变预测、可靠性评估和剩余寿命评估进行具体示例描述。

根据式(4-38)所示的模型参数后验分布，结合式(4-40)所示的主机厂与用户厂性能检测数据融合分析的方法，可以得到恒定速率模型下的后验分布表达式为：

$$\begin{aligned}
 p(\boldsymbol{\mu}, \delta_{\mu}, \gamma_{\mu}, \lambda | \mathbf{Y}^M, \mathbf{Y}^U) &\propto \pi(\delta_{\mu}) \pi(\gamma_{\mu}) \pi(\lambda) L(\mathbf{Y}^M, \mathbf{Y}^U, \boldsymbol{\mu} | \delta_{\mu}, \gamma_{\mu}, \lambda) \\
 &\propto \delta_{\mu}^{a_{\delta}-1} e^{-b_{\delta} \delta_{\mu}} \times \gamma_{\mu}^{a_{\gamma}-1} e^{-b_{\gamma} \gamma_{\mu}} \times \lambda^{-1} e^{-(\ln \lambda - \mu_{\lambda})^2 \sigma_{\lambda}^{-2} / 2} \times \\
 &\quad \prod_{i=1}^n \frac{\gamma_{\mu}^{\delta_{\mu}} \mu_i^{\delta_{\mu}-1} e^{-\gamma_{\mu} \mu_i}}{\int_0^{\infty} x^{\delta_{\mu}-1} e^{-x} dx} \times \left\{ \prod_{j=2}^{m_i^M} \sqrt{\lambda (\mu_i \Delta t_{ij}^M)^2} \exp \left(-\frac{\lambda (\Delta y_{ij}^M - \mu_i \Delta t_{ij}^M)^2}{2 \Delta y_{ij}^M} \right) \right\} \times \quad (4-47) \\
 &\quad \left\{ \prod_{j=2}^{m_i^U} \sqrt{\lambda (\mu_i \Delta t_{ij}^U)^2} \exp \left(-\frac{\lambda (\Delta y_{ij}^U - \mu_i \Delta t_{ij}^U)^2}{2 \Delta y_{ij}^U} \right) \right\}
 \end{aligned}$$

式中， $\Delta y_{ij}^M = y(t_{ij}^M) - y(t_{i,j-1}^M)$ 为主机厂性能检测数据 \mathbf{Y}^M 对应的演变增量， m_i^M 为第 i 个样本在主机厂检测的次数， $\Delta y_{ij}^U = y(t_{ij}^U) - y(t_{i,j-1}^U)$ 为用户厂性能检测数据 \mathbf{Y}^U 对应的演变增量， m_i^U 为第 i 个样本在用户厂检测的次数。

对于式(4-47)所示后验分布的抽样，在 OpenBUGS 软件实现的步骤如图 4-5 所示。该求解实现主要包括两大环节：先验分布的表达和似然函数的表达。

1) 先验分布的表达

先验分布分为固定参数 λ 的先验分布以及超参数 δ_{μ} 和 γ_{μ} 的先验分布。这些参数的先验分布都可以通过 OpenBUGS 内部的概率分布来进行表达，需要特别注意的是 OpenBUGS 中伽玛分布和对数正态分布的参数形式与式(4-47)中所用分布的参数形式存在细微的差别。OpenBUGS 中伽玛分布的尺度参数 `b_delta` 和 `b_gamma` 是式(4-47)中伽玛分布速率参数 b_{δ} 和 b_{γ} 的倒数，OpenBUGS 中对数正态分布的精度参数 `sigma_lambda` 是式(4-47)中对数正态分布方差参数 σ_{λ} 二次方的倒数。

2) 似然函数的表达

似然函数的表达分为两部分：一部分是主机厂性能检测数据的似然函数，另一部分是用户厂性能检测数据的似然函数。这两部分似然函数都是通过从性能检测数据中获得演变增量 $\Delta Y(t)$ ，然后根据演变增量服从逆高斯分布的性质将其演变增量表示成逆高斯分布中的样本即 $\Delta Y(t) \sim \text{IG}(\Delta \Lambda(t), \lambda \Delta \Lambda(t)^2)$ ，该分布中的参数 $\Delta \Lambda(t)$ 和 $\lambda \Delta \Lambda(t)^2$ 与所采用的模型的参数相关联。在 OpenBUGS 中 `deltaY_M` 和 `deltaY_U` 分别表示主机厂和用户厂性能演变增量 $\Delta Y(t)$ ，逆高斯分布则通过

$\text{deltaY_M}[i, j] \sim \text{dinv.gauss}(a_M[i, j], b_M[i, j])$ 和 $\text{deltaY_U}[i, j] \sim \text{dinv.gauss}(a_U[i, j], b_U[i, j])$ 来表达。这两个分布中对应的参数 a_M 、 b_M 、 a_U 、和 b_U 则与模型参数 μ 和 λ 之间建立了关系。

```

model{
#####模型参数的先验分布#####
# 固定参数 lambda 的先验分布
lambda ~ dlnorm(mu_lambda, sigma_lambda)
# 随机参数 mu 的随机效应模型（伽玛分布）对应超参数的先验分布
delta_mu ~ dgamma(a_delta, b_delta)
gamma_mu ~ dgamma(a_gamma, b_gamma)
#####数据的似然函数#####
for (i in 1:n){ # n 个装备样本
# 随机参数 mu 的对应于每一个样本的取值
gamma_mu_BUGS <- 1/ gamma_mu
mu[i] ~ dgamma(delta_mu, gamma_mu_BUGS)
# 主机厂性能退化数据 Y_M 的似然函数
for (j in 2:m_M[i]){ # 第 i 个装备样本对应 m_M[i]个观测值 deltaY_M[i, j]
deltaY_M[i, j] <- Y_M[i, j] - Y_M[i, j - 1] # 退化增量
deltaLambda_M[i, j] <- mu[i] * (t_M[i, j] - t_M[i, j - 1]) # 均值函数增量
a_M[i, j] <- deltaLambda_M[i, j] # 逆高斯分布的参数
b_M[i, j] <- lambda * pow(deltaLambda_M[i, j], 2) # 逆高斯分布的参数
deltaY_M[i, j] ~ dinv.gauss(a_M[i, j], b_M[i, j]) # 退化增量服从逆高斯分布
}
# 用户厂性能退化数据 Y_U 的似然函数
for (j in 2:m_U[i]){ # 第 i 个装备样本对应 m_U[i]个观测值 deltaY_U[i, j]
deltaY_U[i, j] <- Y_U[i, j] - Y_U[i, j - 1]
deltaLambda_U[i, j] <- mu[i] * (t_U[i, j] - t_U[i, j - 1])
a_U[i, j] <- deltaLambda_U[i, j]
b_U[i, j] <- lambda * pow(deltaLambda_U[i, j], 2)
deltaY_U[i, j] ~ dinv.gauss(a_U[i, j], b_U[i, j])
}
}
}
}

```

图 4-5 基于贝叶斯方法的性能检测数据分析的 OpenBUGS 实现

性能演变预测、可靠性评估和剩余寿命评估的求解实现主要采用数值积分的方法。当采用 MCMC 方法获得模型参数 $(\mu, \delta_\mu, \gamma_\mu, \lambda)$ 的后验分布样本集 $\{(\tilde{\mu}, \tilde{\delta}_\mu, \tilde{\gamma}_\mu, \tilde{\lambda})^{(k)}, k=1, \dots, K\}$ 之后 (K 为样本量的大小), 针对个体的性能演变预测、可靠性评估和剩余寿命评估利用模型样本集中的 $\{(\tilde{\mu}, \tilde{\lambda})^{(k)}, k=1, \dots, K\}$, 对于总体则采用样本集中的 $\{(\tilde{\delta}_\mu, \tilde{\gamma}_\mu, \tilde{\lambda})^{(k)}, k=1, \dots, K\}$ 。

1) 针对个体的性能演变预测、可靠性评估和剩余寿命评估

步骤 1: 取模型参数后验分布样本集 $\{(\tilde{\mu}, \tilde{\lambda})^{(k)}, k=1, \dots, K\}$ 中针对第 i 个机床的

一组模型参数样本 $(\tilde{\mu}_i, \tilde{\lambda})^{(k)}$ 。

步骤 2: 将该组样本 $(\tilde{\mu}_i, \tilde{\lambda})^{(k)}$ 代入到式(4-15)和(4-16)中, 获得在观测时刻 t_{i,m_i+l} 的性能演变的预计值 $\tilde{y}(t_{i,m_i+l})^{(k)}$ 和可靠性的评估值 $\tilde{R}(t_{i,m_i+l})^{(k)}$ 。

步骤 3: 判断 $\tilde{y}(t_{i,m_i+l})^{(k)} \geq D$ 是否成立, 当不成立时, 用 $t_{i,m_i+l} + \Delta t$ 来替换 t_{i,m_i+l} 并重复步骤 2 和步骤 3 直至 $\tilde{y}(t_{i,m_i+l})^{(k)} \geq D$ 成立。

步骤 4: 计算 $t_{i,m_i+l} - t_{im_i}$ 得到剩余寿命的评估值 $(T_i^{RUL})^{(k)}$ 。

步骤 5: 重复步骤 1 至步骤 4, 获得所有 K 组模型参数样本下第 i 个机床性能演变预测值、可靠性评估值和剩余寿命评估值的集合。

步骤 6: 分析性能演变预测值、可靠性评估值和剩余寿命评估值的集合, 获得第 i 个机床相应预测值和估计值的均值、方差、置信区间和核分布。

步骤 7: 重复步骤 1 至步骤 6, 获得总体中所有 n 个机床相应性能演变预测、可靠性评估和剩余寿命评估的结果。

2) 针对总体的性能演变预测、可靠性评估和剩余寿命评估

步骤 1: 取模型参数后验分布样本集 $\left\{(\tilde{\delta}_\mu, \tilde{\gamma}_\mu, \tilde{\lambda})^{(k)}, k=1, \dots, K\right\}$ 中的一组模型参数样本 $(\tilde{\delta}_\mu, \tilde{\gamma}_\mu, \tilde{\lambda})^{(k)}$ 。

步骤 2: 将该组样本 $(\tilde{\delta}_\mu, \tilde{\gamma}_\mu, \tilde{\lambda})^{(k)}$ 代入到式(4-26)和(4-27)中, 获得在观测时刻 t_{m+l} 的性能演变的预计值 $\tilde{y}(t_{m+l})^{(k)}$ 和可靠性的评估值 $\tilde{R}(t_{m+l})^{(k)}$ 。

步骤 3: 判断 $\tilde{y}(t_{m+l})^{(k)} \geq D$ 是否成立, 当不成立时, 用 $t_{m+l} + \Delta t$ 来替换 t_{m+l} 并重复步骤 2 和步骤 3 直至 $\tilde{y}(t_{m+l})^{(k)} \geq D$ 成立。

步骤 4: 计算 $t_{m+l} - t_{im}$ 得到剩余寿命的评估值 $(T^{RUL})^{(k)}$ 。

步骤 5: 重复步骤 1 至步骤 4, 获得所有 K 组模型参数样本下机床总体的性能演变预测值、可靠性评估值和剩余寿命评估值的集合。

步骤 6: 分析性能演变预测值、可靠性评估值和剩余寿命评估值的集合, 获得机床总体相应预测值和估计值的均值、方差、置信区间和核分布。

对于其他模型下后验分布的抽样、性能演变预测、可靠性评估和剩余寿命评估的实现可以依照以上的算法和步骤来类比完成, 在此不再赘述。

4.5 算例分析

定位精度作为重型数控机床的一个重要性能指标, 在机床的验收时是重点考核的关键性能指标之一。本章将通过对某重型数控机床主机厂和用户厂所采集到的定位精度的检测数据进行建模分析和可靠性评估, 来对本文所提出的模型和所构建的方法进行应用性示范。在此基础上, 进一步通过性能演变预测的交叉验证来对模型和方法进行验证。

出于方法示例性说明以及主机厂和用户厂信息的保护，本文所采用的数据是对原有数据进行适当处理之后，保留性能检测数据的特性而剔除相关指标参数细节而得到的示例数据。这样可以将重点集中在性能检测数据分析、建模以及基于数据分析的可靠性评估上。

4.5.1 性能检测数据

本章所采用的数据为 5 台重型机床样本定位精度的性能检测数据，分别如图 4-6 和表 4-1 所示。由于受到测试设备和人员以及机床加工任务的限制，这些性能检测数据都是在机床加工任务的空闲时间采集获得的。

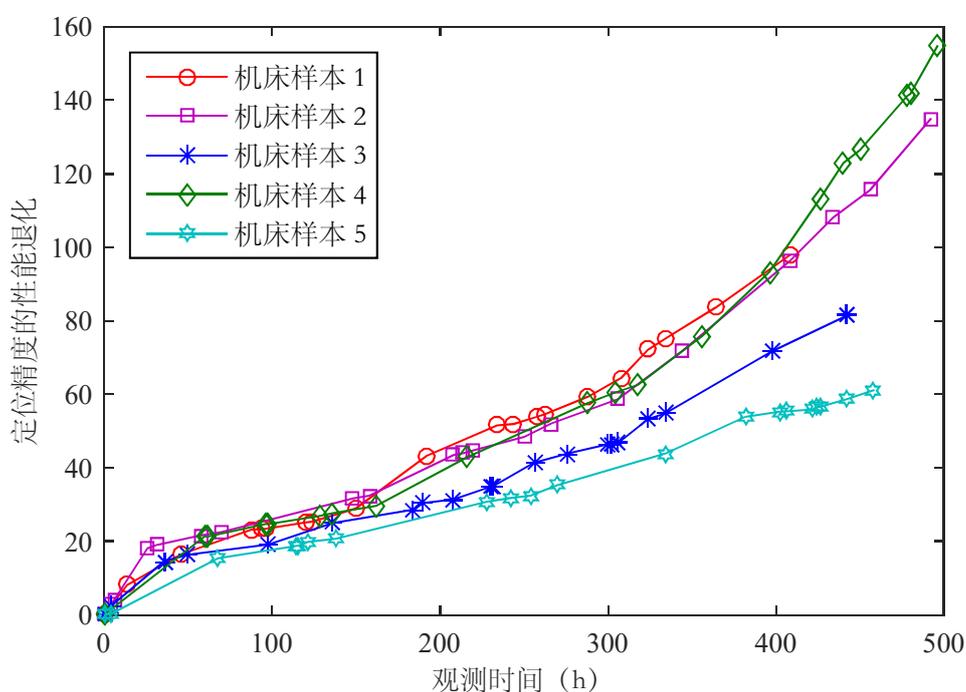


图 4-6 定位精度的性能检测数据

令 $Y(t)$ 为机床的定位精度性能演变过程，可将性能演变观测数据描述为： $y(t_{ij})$ ($i=1, \dots, 5, j=1, \dots, m$)，其中 i 为机床样本的系数， j 为观测点的系数。 $y(t_{ij})$ 即为第 i 个机床样本在第 j 个观测时间点观测到的性能检测值。此外，机床定位精度性能演变过程的阈值为 $D = 300$ 。

表 4-1 定位精度的性能检测数据 (时间: h)

机床样本 1	检测时间	14	46	88	94	96	120	124	150	192	234
	检测量	8	17	23	23	23	25	25	29	43	52
	检测时间	244	258	262	288	308	324	334	364	408	
	检测量	52	54	55	59	65	72	75	84	98	
机床样本 2	检测时间	4	6	26	32	58	70	148	158	208	214
	检测量	3	4	18	19	22	23	32	32	43	44
	检测时间	220	250	266	306	344	408	434	456	492	
	检测量	45	48	52	59	72	96	108	116	135	
机床样本 3	检测时间	4	36	50	98	136	184	190	208	230	232
	检测量	2	15	16	19	25	29	30	31	35	35
	检测时间	256	276	300	302	306	324	334	398	442	
	检测量	41	44	46	47	47	53	55	72	81	
机床样本 4	检测时间	60	62	96	98	128	136	162	216	288	304
	检测量	21	21	25	25	27	28	30	43	58	60
	检测时间	318	356	396	426	440	450	478	480	496	
	检测量	63	76	93	113	123	126	141	142	155	
机床样本 5	检测时间	4	68	114	116	122	138	228	242	254	270
	检测量	0	15	19	19	20	21	31	32	32	35
	检测时间	334	382	402	406	422	424	426	442	458	
	检测量	44	54	55	55	56	56	57	59	61	

4.5.2 性能检测数据的建模与模型参数估计

在获得机床定位精度的性能检测数据之后, 根据图 4-6 中性能演变轨迹所表现出的形式, 结合 4.3.2 节中所提出的不同性能速率形式的性能演变过程模型的特性, 选择 S 型速率的性能演变过程来对定位精度的性能演变过程进行建模。选择该性能演变过程模型主要是考虑机床在使用初期的精度性能演变往往与机床的机械零部件的磨合有一定的关联关系, 在使用初期往往存在一个性能演变速率增长较快而后逐渐降低直至较为稳定的阶段。根据式(4-23)所示的 S 型速率的性能演变过程模型, 定位精度的性能演变过程 $Y(t)$ 可通过其演变增量的模型描述为:

$$\begin{aligned}\Delta y_{ij} &\sim \text{IG}\left(\Delta\Lambda_{ij}, \lambda(\Delta\Lambda_{ij})^2\right), \Delta y_{ij} = y(t_{ij}) - y(t_{i,j-1}), \\ \Delta\Lambda_{ij} &= \nu_i \exp\left(\alpha\left(\frac{t_{ij}}{\nu_i}\right) - \omega\left(\frac{t_{ij}}{\nu_i}\right)^{-1}\right) - \nu_i \exp\left(\alpha\left(\frac{t_{i,j-1}}{\nu_i}\right) - \omega\left(\frac{t_{i,j-1}}{\nu_i}\right)^{-1}\right), \\ \nu_i &\sim \text{Gamma}(\delta_\nu, \gamma_\nu), i=1, \dots, 5, j=2, \dots, m\end{aligned}\quad (4-48)$$

式中, 模型参数中的固定参数为 $\boldsymbol{\theta}^F = \{\alpha, \omega, \lambda\}$, 考虑了样本个体差异性的随机参数为 $\boldsymbol{\theta}_{1:5}^R = \{\nu_1, \dots, \nu_5\}$, 随机参数概率分布模型对应的超参数为 $\boldsymbol{\theta}^H = \{\delta_\nu, \gamma_\nu\}$ 。

根据 4.4 节中构建的基于贝叶斯方法的性能检测数据分析方法, 首先给出性能演变过程模型中模型参数的先验分布如下:

$$\begin{aligned}\alpha &\sim \text{Uniform}(0, 0.25), \omega \sim \text{Uniform}(0, 1), \\ \delta_\nu &\sim \text{Uniform}(0, 100), \gamma_\nu \sim \text{Uniform}(0, 100), \lambda \sim \text{Uniform}(0, 100)\end{aligned}\quad (4-49)$$

本文采用均匀分布形式的无信息先验分布来对性能检测数据进行分析。这一方面是受到可用先验信息的限制, 另一方面是为了使分析结果完全符合性能检测数据所包含的信息并为模型对比提供一致的信息基础。均匀分布区间的选择需要考虑模型的取值范围, 由于参数 α 和 ω 的取值区间都为有限区间, 则可以将均匀分布的区间选为各自的取值范围区间; 对于其他参数的取值区间都为无限区间, 则可以根据模型中各参数取值的影响程度选择一个较大的区间。

进一步, 根据式(4-48)所示的定位精度的性能演变过程 $Y(t)$ 的模型, 通过似然函数将表 4-1 中性能检测数据所包含的信息描述为:

$$\begin{aligned}L(\mathbf{Y}, \boldsymbol{\theta}_{1:5}^R | \alpha, \omega, \delta_\nu, \gamma_\nu, \lambda) &= \prod_{i=1}^5 g_\nu(\nu_i | \delta_\nu, \gamma_\nu) \prod_{j=2}^m f(\Delta y_{ij} | \Delta\Lambda_{ij}, \lambda(\Delta\Lambda_{ij})^2) \\ &= \prod_{i=1}^5 \frac{\gamma_\nu^{\delta_\nu} \nu_i^{\delta_\nu-1}}{\Gamma(\delta_\nu)} \exp(-\gamma_\nu \nu_i) \prod_{j=2}^m \sqrt{\frac{\lambda(\Delta\Lambda_{ij})^2}{2\pi(\Delta y_{ij})^3}} \exp\left(-\frac{\lambda(\Delta y_{ij} - \Delta\Lambda_{ij})^2}{2\Delta y_{ij}}\right)\end{aligned}\quad (4-50)$$

式中, \mathbf{Y} 为性能检测数据, Δy_{ij} 和 $\Delta\Lambda_{ij}$ 可参见式(4-48)中对应的表达式。

根据基于贝叶斯方法的性能检测数据分析方法, 在得到模型参数的先验分布与观测数据的似然函数的条件下, 通过贝叶斯公式即可获得模型参数估计的表达式:

$$p(\boldsymbol{\theta}_{1:5}^R, \alpha, \omega, \delta_\nu, \gamma_\nu, \lambda | \mathbf{Y}) \propto \pi(\alpha, \omega, \delta_\nu, \gamma_\nu, \lambda) L(\mathbf{Y}, \boldsymbol{\theta}_{1:5}^R | \alpha, \omega, \delta_\nu, \gamma_\nu, \lambda) \quad (4-51)$$

根据 4.4.3 节中描述的后验分布抽样的算法, 通过 OpenBUGS 软件来对模型参数的后验分布进行 MCMC 抽样, 基于后验样本获得的模型参数估计结果如表 4-2。

表 4-2 模型参数的估计结果

模型参数	统计特征值		后验置信区间		
	均值	方差	2.5%	97.5%	
固定参数	α	0.05966	0.004859	0.0511	0.07019
	λ	1.539	0.4336	0.8067	2.493
	ω	0.6116	0.1734	0.2784	0.9501
超参数	δ_v	69.89	21.33	22.91	98.81
	γ_v	4.114	1.359	1.311	6.527
随机参数	ν_1	17.89	3.126	12.43	24.58
	ν_2	17.97	2.914	12.69	24.07
	ν_3	17.23	2.517	12.78	22.69
	ν_4	16.2	3.227	10.55	23.3
	ν_5	17.11	2.514	12.66	22.66

4.5.3 模型验证与可靠性评估

本节将采用交叉验证和模型对比的方法来对所建立的模型进行验证，并在模型得到验证之后对机床的可靠性进行评估。

为了对模型进行验证，将表 4-1 中所示的数据分成两部分：所有样本的前 16 个观测点的数据用来作为模型参数估计的观测值（参数信息点）；所有样本的后 3 个观测点的数据用来作为模型验证的观测值（交叉验证点）。以上给出的模型参数评估结果是参数信息点对应性能检测数据所包含信息的反应。在此基础上，应用 4.4.3 节中所描述的性能演变预测的方法，首先对交叉验证点的性能演变进行预测，然后通过对比交叉验证点预测的结果与实际观测的结果，即可对模型的建模能力和方法的预测能力进行判断，其对比结果如图 4-7 所示。从图中得出预测结果的箱形图（箱形图的上下边分别对应于预测结果 90%置信区间的上下界，中间直线对应于预测结果的均值）基本涵盖了实际观测值。这说明了交叉验证点的性能演变预测值与实际观测值相接近，本文所构建的模型能对定位精度性能演变过程进行较好的建模，且本文所提出的性能演变预测方法具有较好的性能演变预测能力。

在模型的有效性通过交叉验证之后，即可在此基础上应用 4.4.3 节所构建的可靠性评估方法来对机床的可靠性进行评估。基于模型参数后验分布的样本，应用 4.4.3 节中的方法，依次对样本个体的剩余寿命、可靠性以及总体的可靠性进行评估，其结果如图 4-8 所示。从图中可以得到不同机床样本的剩余寿命的概率密度和

故障概率密度函数的分布形式存在一定的差别，这说明同型号机床由于制造、装配和使用等环节的多种因素的影响使其表现出来的可靠性存在一定的个体差异性。这也从另一个侧面说明了在性能演变过程建模中引入考虑个体差异性的随机效应模型的必要性。

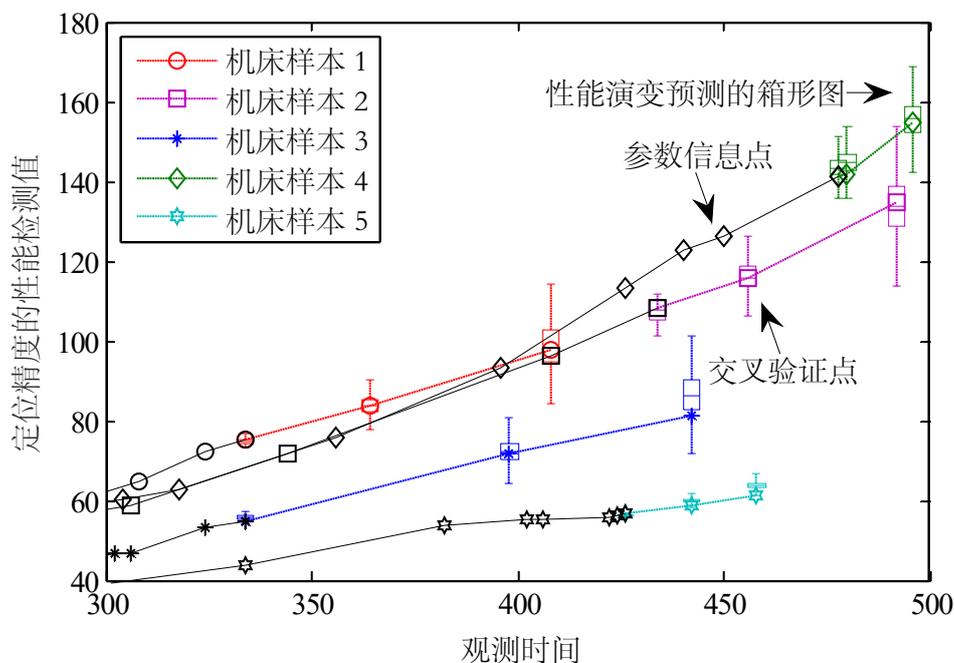


图 4-7 交叉验证点的性能演变预测值与观测值对比

分析各样本的性能演变过程和剩余寿命的分布可知：机床样本 4 的性能演变得最快，与之对应的剩余寿命在 5 个样本中最短且其剩余寿命概率分布的离散度最小；而机床样本 5 的性能演变最慢，其剩余寿命最长且其对应的概率分布相对较为离散。剩余寿命概率分布的离散性与剩余寿命的长短相关联。这是因为剩余寿命越长其在故障发生之前需要经历的时间增量的区间越多，在每个观测时间增量区间内性能演变增量的预测都存在一定的不确定性，从而导致累积的不确定性最多并使得剩余寿命概率分布的离散性增加。在实际工程中，往往是根据性能检测数据的动态观测来对剩余寿命进行动态预测，用最新观测的性能检测数据来预测机床的剩余寿命，以降低剩余寿命预测中累积的不确定性。

对比样本总体和各样本的故障概率密度函数可知，总体的故障概率密度函数基本覆盖了所有样本故障概率密度函数的区间。这是因为在计算总体的故障概率密度函数时需要将所有样本个体对应的随机参数的不确定性都考虑进去，而各个样本的故障概率密度函数只需要考虑本身随机参数的不确定性。

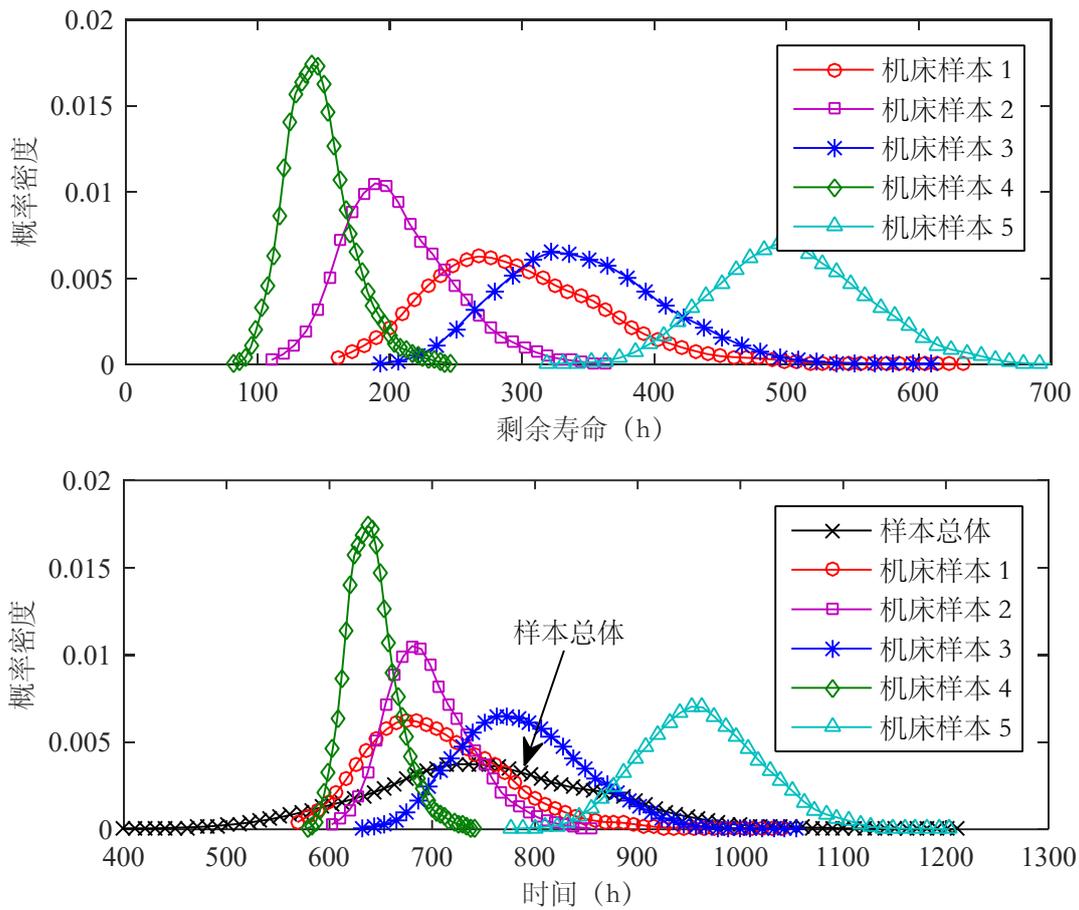


图 4-8 剩余寿命和可靠性评估结果

4.6 本章小结

本章针对重型数控机床性能检测数据建模分析中存在的性能演变形式多、个体差异性大、性能波动性强等特性以及主机厂和用户厂协同考核评估的实际需求，研究了重型数控机床基于性能检测数据的可靠性建模与评估技术。首先，在现有基于随机过程的性能演变过程模型的基础上，通过将性能演变速率函数引入到逆高斯过程模型中，构建了多种性能演变速率形式的性能演变过程模型以实现重型数控机床多种演变轨迹形式的描述；然后将随机影响模型引入到所建立的逆高斯过程模型中，并与逆高斯过程模型中参数的物理特性相结合，实现了考虑个体差异性和性能波动性的性能演变过程模型的构建。在此基础上，提出了基于贝叶斯方法的性能检测数据分析的基本框架，重点研究了基于贝叶斯方法的性能演变过程模型参数估计、性能演变预测和剩余寿命预测的实现方法；并进一步利用贝叶斯方法的信息融合能力，构建了融合主机厂与用户厂性能检测数据的可靠性评估方法，实现了两者性能检测数据的协同分析与评估结果的动态更新。最后，

通过算例分析对本章所提出的建模和评估方法进行了示例展示。算例分析表明：通过引入性能演变速率而改进的逆高斯过程模型能够对性能演变轨迹较为复杂的性能演变过程进行较好的描述；通过引入随机效应模型的性能演变过程模型能够对重型数控机床的个体差异性和性能波动性进行较好的表征。

第五章 基于状态监测数据的重型数控机床可靠性建模与评估

重型数控机床的服役阶段是机床根本价值体现的阶段，如何在服役阶段保持机床高的可靠性，同时降低使用和维护等产生的费用是机床用户厂面临的重大难题。随着机床状态监测技术的发展，以状态监测技术为基础的机床故障诊断和健康管理技术在提高使用可靠性和降低总体拥有成本方面正逐渐取得成效，而其中基于状态监测的可靠性建模与评估则是影响其实施成败的关键环节之一。对于重型数控机床而言，由于其系统结构的复杂、性能指标的多样、工作环境的多变以及小批量定制的特点，使得其基于状态监测的可靠性建模与评估面临两大挑战：一方面需要解决动态环境与任务应力下多性能退化相关建模与分析的关键问题，另一方面需要解决不完全状态监测数据下机床性能退化预测、剩余寿命评估以及结果不确定性表征的实际需求。本章将针对重型数控机床服役阶段的关键问题和实际需求，从多性能退化的角度研究适用于重型数控机床状态监测数据建模、分析与可靠性评估的方法，为重型数控机床服役阶段的使用维护 and 健康管理提供技术支持。

5.1 引言

随着重型数控机床服役阶段的开始，机床可靠性的工作重心由主机厂为核心的固有可靠性的提高逐渐转变为用户厂为核心的使用可靠性保证。重型数控机床的根本价值也随着服役阶段的推进而逐渐显现出来。对于用户厂而言，重型数控机床高可靠、长寿命、高效率的运作是其产生经济效益的关键所在。多数重型数控机床在用户厂都是当家把关的核心装备，机床的故障和意外停机不仅会导致生产的中断，而且有可能导致安全事故的发生造成重大的经济损失。与此同时，机床使用和维护所产生的费用即对用户厂而言的总体拥有成本也逐渐在提高。为了在有限的总体拥有成本下达到最大的经济效益，主机厂使用和维护的相关技术由以往的事后维修和基于时间的预防性维修逐渐发展为了基于状态的视情维修。基于状态的视情维修关键在于通过对机床的运行状态进行监控，并在此基础上预测和诊断机床发生故障的时机，以此实现对机床的健康进行管理。这使得基于状态监测数据的可靠性建模与评估技术成为机床服役阶段的关键技术之一。

对于多数普通机床而言，状态监测数据多为机床的性能退化数据，且为单一性能指标的性能退化数据。针对这样的状态监测数据，学术界和工程界在可靠性建模与评估^[86, 92, 96]、维修决策^[71, 72, 98, 100]等方面的研究较多。这些现有方法和技术

的典型特征是理想环境下的单性能退化建模、评估与决策；其中理想环境是指机床的环境应力和工作应力对机床性能退化的影响可以忽略，单性能退化是指机床的可靠性状态往往通过单一性能指标的退化过程来表征。

由于重型数控机床具有系统结构复杂、性能指标多样、工作环境多变以及小批量定制的特性，其可靠性状态往往与多个性能指标相关联且多性能指标之间存在一定的关系^[164-167]。这些性能指标一方面会受到所处的环境应力的影响，如温度、振动和湿度等；另一方面会受到所承载的工作应力的影响，如高工作负荷产生的内部应力等。因此，基于理想环境下单性能退化的可靠性建模与评估方法已经难以用于重型数控机床的建模与评估。此外，对于重型数控机床的状态监测而言，由于涉及到多性能退化指标的监测，不同性能指标之间监测的技术方法、人员需求和难易程度不近相同，在实际中往往会发生某一性能指标监测信息的缺失，即不完全状态监测信息的情形。基于不完全监测信息的机床性能退化分析和可靠性评估已成为重型数控机床在实际工程中面临的一大难题。

因此，本章在现有状态监测数据建模、分析与机床可靠性评估技术的基础上，从多性能退化的角度进一步考虑动态环境工作应力的影响，来研究不完全状态监测信息下重型数控机床基于状态监测数据的可靠性建模与评估。

5.2 重型数控机床状态监测数据

重型数控机床的状态监测数据虽然与性能退化数据相类似，但是对于重型数控机床而言状态监测数据主要包括机床本身的性能退化数据和机床外在的环境与工作应力信息。机床本身的性能退化数据是指针对机床的关键特性与功能，通过采用适当的测量仪器与技术来获取，并经过信号处理、参数提取与融合所得到的，能够反应机床内在状态退化程度和趋势的可靠性数据。机床外在的环境与工作信息是指机床所处的工作环境和机床所承担的工作任务的信息，如重型数控机床所处厂房环境的温度、湿度和振动等信息以及其所经历加工任务的类型、进给和转速等信息。

重型数控机床状态监测中对多性能指标的监控是为了对机床的内在变化进行全面和实时的把握。重型数控机床多性能退化指标往往包括与机床功能输出相关的性能指标，如重型数控机床的精度指标，同时也包括与机床系统运行相关的性能指标，如重型数控机床液压系统的性能指标。对于功能输出相关的性能指标的监测，由于受到监测指标特殊性的影响以及测量仪器和手段的限制，其监测过程往往与机床的加工任务相冲突，因此需要在机床加工任务的间隙通过采用特殊的测量仪器和手段来获取这些性能指标的监测值。受到仪器设备、加工任务和测试

人员的影响，对于功能输出相关的性能指标的监测往往在某些监测点无法展开而导致监测数据缺失，使得其性能退化数据表现为不完整的稀疏型退化数据。对于机床系统运行相关的性能指标的监测，可以在系统中置入相关的传感器和监测装置来对其进行连续实时的监测，其性能退化数据往往表现为完整的连续型退化数据。因此，就数据的表现形式和质量而言，重型数控机床状态数据中的性能退化数据为多性能退化数据且不同指标的数据完整程度不一。

重型数控机床状态监测中对环境与工作应力的监控是为了对机床的外在因素进行全面和实时的把握。重型数控机床往往受到环境与工作应力的影响而表现出不同的性能退化特性，且机床的多性能退化指标在动态环境与任务应力的影响下存在着不可避免的相关性，这些使得环境与工作应力的监测成为重型数控机床状态监测不可或缺的环节。重型数控机床的环境与工作应力主要包括机床所处的环境条件和任务工况两方面的内容。对于环境条件的监测往往采用现有的仪器设备进行自动的信息采集与记录，往往表现为完整的连续型环境监测数据。对于任务工况的监测往往需要结合机床的生产任务计划以及运行操作记录来完成，一方面需要借助于机床的生产管理信息的自动记录，另一方面需要任务操作人员的手动输入。由于关系到重型数控机床的任务工况指标众多，难以对其进行全面的记录，使得任务工况信息表现为局部的离散型任务监测数据。

由性能退化数据和环境与工作应力信息所构成的重型数控机床状态监测数据，较之于普通机床理想环境下单一性能退化数据而言，可以对重型数控机床的状态进行全面实时的反应。然而，这需要对状态监测数据进行正确的建模与分析，并在此基础上对机床的可靠性进行有效的评估。根据以上对重型数控机床状态监测数据的分析可知，重型数控机床状态监测数据就其表现形式而言可描述为：动态环境与任务应力下不完全的多性能退化数据；就其内在特性而言可描述为：环境与工作应力交互影响下多性能指标相关的性能退化数据。因此，本章将针对重型数控机床基于状态监测数据的可靠性建模与评估，重点突破并解决以下关键问题：多相关性能指标的性能退化建模与分析问题、动态环境与任务应力作用下的多性能退化建模与分析问题以及基于不完全状态监测信息的可靠性评估问题。

5.3 重型数控机床状态监测数据的建模

基于状态监测数据的可靠性评估首先需要解决状态监测数据的建模问题。本节针对重型数控机床状态监测数据建模中的多相关性能指标的退化建模与动态环境与任务应力作用下的多性能退化建模问题展开研究。首先构建重型数控机床状态监测数据建模的基本框架，然后在基本框架下逐个突破退化相关情形下的多性

能退化建模以及动态环境与任务应力下的多性能退化建模问题。

5.3.1 动态环境与任务应力下多性能退化建模的基本框架

重型数控机床考虑环境与工作应力影响的多相关性能退化过程建模的基本框架如图 5-1 和图 5-2 所示。图中的公式和表达式将在后续描述中进行详细说明。该框架主要包括两大部分：1) 多相关性能退化过程的建模；2) 动态环境与任务应力下的多性能退化建模。

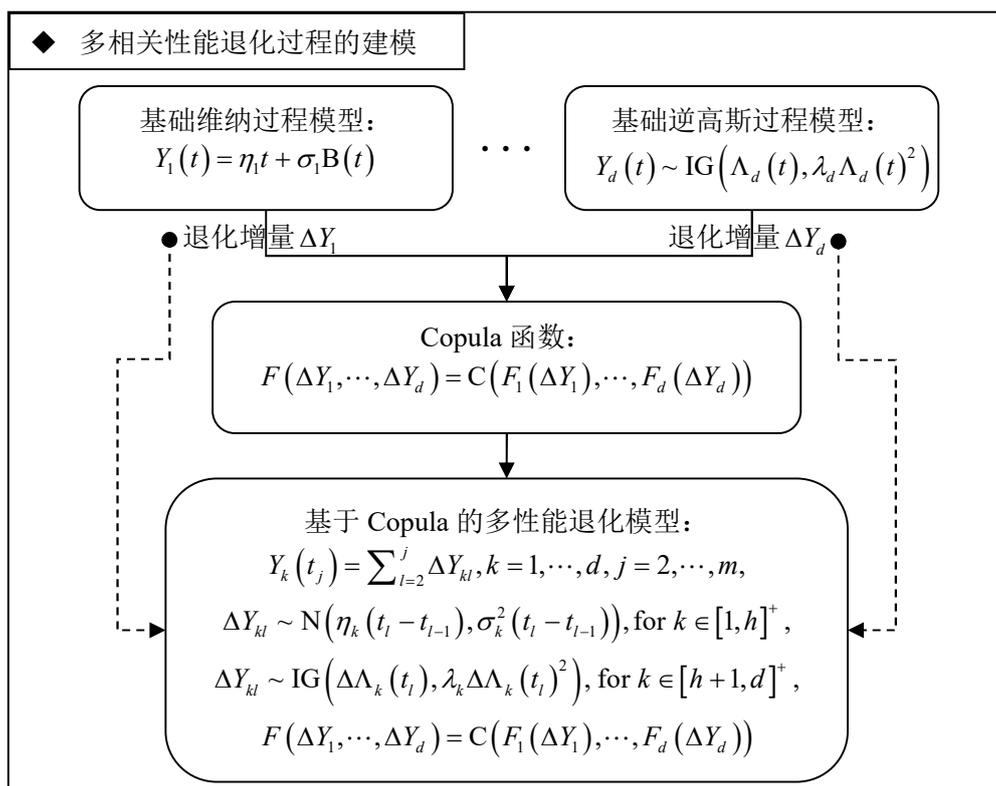


图 5-1 多相关性能退化过程建模的框架

多相关性能退化过程建模的框架如图 5-1 所示，其核心在于以维纳过程模型和逆高斯过程模型为基础，以 Copula 函数为相关关系建模的基本框架，构建多个性能退化过程相关的退化过程模型。多相关性能退化建模的框架如图 5-2 所示，其核心在于以维纳过程模型和逆高斯过程模型的均值函数为影响因素引入点，以协变量和加速退化模型为环境和任务应力建模的基本框架，构建动态环境与任务应力下的多性能退化过程模型。

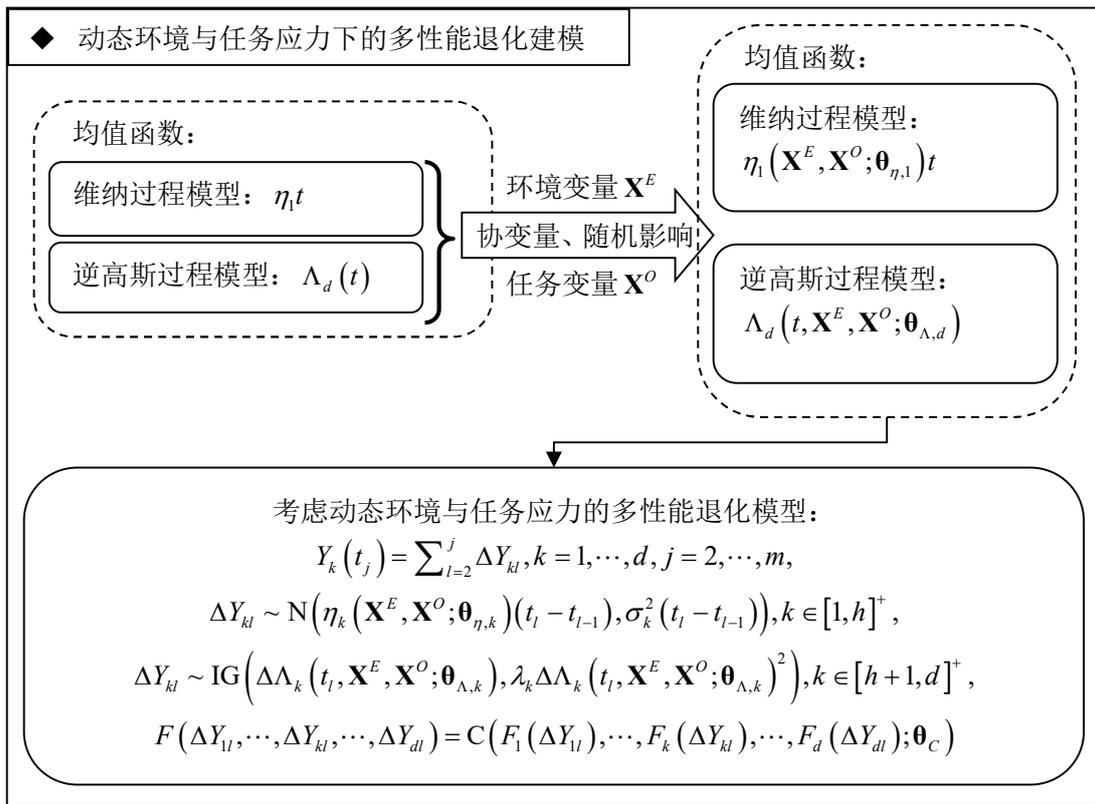


图 5-2 考虑动态环境与任务应力的多性能退化建模基本框架

5.3.2 基于 Copula 的多性能退化建模

根据图 5-1 所示的建模框架，基于 Copula 的多相关性能退化建模主要包括：基础性能退化模型的构建，基于 Copula 的多性能退化过程相关关系构建以及基于 Copula 的多性能退化模型形成。下面根据基于 Copula 的多相关性能退化建模的核心思路，依次对其包含的三大部分进行研究描述，并在此基础上构建基于 Copula 的多性能退化过程模型。

5.3.2.1 基础性能退化过程模型

令某重型数控机床的状态监控过程中包含了对 d 个性能指标的监控，其对应的性能退化过程为 $\{Y_k(t), t \geq 0\}$ ($k=1, \dots, d$) 且有 $Y_k(0)=0$ 。在这 d 个性能退化过程中，每一个性能退化过程称为边缘退化过程 (Marginal Degradation Process)，在建立多性能退化过程模型时，首先需要对各个边缘退化过程建模。对于重型数控机床的多性能退化过程，根据性能指标的差异和退化机理的不同，可能同时存在单调和非单调的退化过程，并且退化过程的轨迹形式存在多种形态。考虑到维纳过程模型对非单调退化过程的建模能力以及逆高斯过程模型对单调退化过程的建模能力，本文分别采用维纳过程模型和逆高斯过程模型来对边缘退化过程进行建模。

假设 d 个性能退化过程中有 h 个为非单调型退化过程, 即 $\{Y_k(t), t \geq 0\}$ ($k=1, \dots, h$) 为非单调性能退化过程; 其他 $d-h$ 个性能退化过程为单调型退化过程, 即 $\{Y_k(t), t \geq 0\}$ ($k=h+1, \dots, d$) 为单调性能退化过程。

(1) 维纳过程模型

根据 4.3.1 节中维纳过程模型描述, 对于 $\{Y_k(t), t \geq 0\}$ ($k=1, \dots, h$), 建立性能退化过程 $Y_k(t)$ 的基本维纳过程模型如下:

$$Y_k(t) = \eta_k t + \sigma_k B(t) \quad (5-1)$$

在该基本维纳过程模型下, 性能退化增量 $\Delta Y_k(t) = Y_k(t + \Delta t) - Y_k(t)$ 具有独立增量的性质且服从正态分布并有 $\Delta Y_k \sim N(\eta_k \Delta t, \sigma_k^2 \Delta t)$ 。令 D_k 为第 k 个性能退化过程的退化阈值, 该性能退化过程所对应的首次穿越时间 $T_k \sim \text{IG}(D_k/\eta_k, D_k^2/\sigma_k^2)$ 且其累积分布函数为:

$$F_k(t) = \Phi\left(\frac{\eta_k t - D_k}{\sigma_k \sqrt{t}}\right) + \exp\left(\frac{2D_k \eta_k}{\sigma_k^2}\right) \Phi\left(-\frac{\eta_k t + D_k}{\sigma_k \sqrt{t}}\right) \quad (5-2)$$

维纳过程模型在性能退化过程的建模中有较为广泛的研究^[157-159]。对于式(5-1)所示的维纳过程模型, 当需要考虑环境与工作应力因素的影响以及机床个体差异性时, 可以将协变量和随机影响模型引入到与退化速率相关的模型参数 η_k 和与退化增量波动性相关的模型参数 σ_k 中, 以实现两者进行描述。

(2) 逆高斯过程模型

根据 4.3.1 节中对逆高斯过程模型描述, 对于 $\{Y_k(t), t \geq 0\}$ ($k=h+1, \dots, d$), 建立性能退化过程 $Y_k(t)$ 的基本逆高斯过程模型如下:

$$Y_k(t) \sim \text{IG}\left(\Lambda_k(t), \lambda_k \Lambda_k(t)^2\right) \quad (5-3)$$

在该基本逆高斯过程模型下, 性能退化增量 $\Delta Y_k(t)$ 具有独立增量的性质且服从逆高斯分布并有 $\Delta Y_k \sim \text{IG}\left(\Delta \Lambda_k(t), \lambda_k \Delta \Lambda_k(t)^2\right)$, $\Delta \Lambda_k(t) = \Lambda_k(t + \Delta t) - \Lambda_k(t)$ 。令 D_k 为第 k 个性能退化过程的退化阈值, 该性能退化过程所对应的首次穿越时间 T_k 的累积分布函数为:

$$\begin{aligned} F_k(t) &= \Pr(T_k \leq t) = \Pr(Y_k(t) \geq D_k | \Lambda_k(t), \lambda_k \Lambda_k(t)^2) \\ &= \Phi\left[\sqrt{\frac{\lambda_k}{D_k}}(\Lambda_k(t) - D_k)\right] - \exp(2\lambda_k \Lambda_k(t)) \Phi\left[-\sqrt{\frac{\lambda_k}{D_k}}(\Lambda_k(t) + D_k)\right] \end{aligned} \quad (5-4)$$

逆高斯过程模型是近年来提出的性能退化模型, 其在模型的物理意义、模型扩展以及模型的实际应用方面都具有较好的优势^[156, 160-161]。对于式(5-3)所示的逆

高斯过程模型，与维纳过程模型类似，当需要考虑环境与工作应力因素的影响以及机床个体差异性时，可以将协变量和随机影响模型较为容易地引入到与退化速率相关的均值函数 $\Lambda_k(t)$ 和与退化增量波动性相关的模型参数 λ_k 中，以实现两者进行描述。

5.3.2.2 基于 Copula 的多性能退化过程相关关系

多相关性能退化建模的关键在于建立多个边缘性能退化过程之间的相关关系。在建立多退化过程之间的相关关系时，一方面需要保持边缘退化过程模型的可获取性，即可以从多性能退化模型中获得各边缘退化过程的模型；另一方面需要保证多性能退化模型中相关关系模型的灵活性，即可以利用相关关系模型来建模多种形式的相关关系。出于这两方面的考虑，本文拟采用 Copula 理论来描述多性能退化过程之间的相关关系。

(1) Copula 理论

Copula 理论是对多个随机变量之间的相关关系进行建模的理论方法^[170-171]。Copula 理论的核心在于利用 Copula 函数对多个随机变量之间的相关关系进行描述。通过 Copula 函数来建立多个随机变量之间的相关关系，可以使各个随机变量的边缘分布与变量之间的相关关系分离开来，即各随机变量的边缘分布模型与基于 Copula 函数的相关关系模型共同构成了多相关随机变量的模型。从多维随机变量的联合累积概率分布的角度， d 维 Copula 函数 $C(u_1, u_2, \dots, u_d)$ 可以定义为：

$$C(u_1, u_2, \dots, u_d) = \Pr(U_1 \leq u_1, U_2 \leq u_2, \dots, U_d \leq u_d) \quad (5-5)$$

式中， u_k ($k=1, \dots, d$) 为 Copula 函数的变量且有 $0 \leq u_k \leq 1$ ， U_k 为服从均匀分布的随机变量且其分布区间为 $[0, 1]$ 。

从 Copula 函数的定义可知：Copula 函数 $C(u_1, u_2, \dots, u_d)$ 实际上是一个 d 维随机变量的联合累积概率分布，这 d 个随机变量之间的相关关系由 Copula 函数的具体表现形式所描述，并且每个随机变量的边缘分布为 $[0, 1]$ 区间上的均匀分布。据此，当需要描述 d 维随机变量 X_1, \dots, X_d 之间的相关关系且已知各随机变量的边缘分布为 $\Pr(X_k \leq x_k) = F_k(x_k)$ 时，可以将各随机变量的边缘分布函数 $F_k(x_k)$ 作为 Copula 函数的输入即令 $u_k = F_k(x_k)$ ，则这 d 个随机变量之间的相关关系描述为：

$$F(x_1, \dots, x_d) = \Pr(X_1 \leq x_1, \dots, X_d \leq x_d) = C(F_1(x_1), \dots, F_d(x_d)) \quad (5-6)$$

式中， $F(x_1, \dots, x_d)$ 为 d 维随机变量 X_1, \dots, X_d 的联合累积概率分布函数，在该联合分布下各随机变量 X_k 的边缘分布为 $F_k(x_k)$ ，随机变量之间的相关关系则通过 Copula 函数 $C(u_1, u_2, \dots, u_d)$ 来构建。常用的 Copula 函数主要包括 Gaussian copula,

Frank copula, Gumbel copula 和 Clayton copula 等用于二维随机变量相关关系建模的 Copula 函数, 以及多变量 t-copula 和 Vine copula 等用于多维随机变量之间相关关系建模的 Copula 函数。

(2) 基于 Copula 函数的多性能退化相关关系描述

对于 d 维性能退化过程中 $\{Y_k(t), t \geq 0\}$ ($k=1, \dots, h$) 为非单调型的退化过程并且采用维纳过程模型对其进行建模, 其他退化过程 $\{Y_k(t), t \geq 0\}$ ($k=h+1, \dots, d$) 为单调型的退化过程并且采用逆高斯过程对其进行建模。在这样的模型假设背景下, 当需要建立 d 维随机过程之间的相关关系时, 考虑到性能退化过程的本质为性能退化增量的逐次累加, 可以通过 d 维随机过程在相同时间增量上退化增量之间的相关关系来进行描述^[168-169]。

令 $\Delta Y_1, \dots, \Delta Y_d$ 为性能退化过程 $\{Y_k(t), t \geq 0\}, k=1, \dots, d$ 中各边缘退化过程在时间增量区间 $[t, t+\Delta t]$ 上的退化增量。根据上文给出的 d 维性能退化过程的模型, 有 $\Delta Y_k \sim N(\eta_k \Delta t, \sigma_k^2 \Delta t)$ ($k=1, \dots, h$), $\Delta Y_k \sim IG(\Delta \Lambda_k(t), \lambda_k \Delta \Lambda_k(t)^2)$ ($k=h+1, \dots, d$), 进一步可以得到各个退化增量的分布函数为 $F_1(\Delta y_1), \dots, F_d(\Delta y_d)$ 。在此基础上, 可以通过 Copula 函数建立 n 维退化过程在相同时间增量区间 $[t, t+\Delta t]$ 上的相关关系模型。据此, $\Delta Y_1, \dots, \Delta Y_n$ 的联合概率分布函数 $F(\Delta y_1, \dots, \Delta y_d)$ 可以描述为:

$$F(\Delta y_1, \Delta y_2, \dots, \Delta y_d) = C(F_1(\Delta y_1), F_2(\Delta y_2), \dots, F_d(\Delta y_d)) \quad (5-7)$$

根据 Copula 函数的性质可知, 式(5-7)中 $F(\Delta y_1, \dots, \Delta y_d)$ 的边缘概率分布为 $F_k(\Delta y_k)$ 且退化增量 ΔY_k 之间的相关关系由 $C(u_1, \dots, u_d)$ 所描述。通过应用不同的 Copula 函数, 可以通过式(5-7)来构建不同相关关系的 d 维退化增量模型。值得指出的是这些相关关系是建立在 d 维退化过程在相同时间增量区间 $[t, t+\Delta t]$ 上的, 对于不相交时间增量区间上的退化增量则假设为相互独立。这一假设既与各边缘随机过程独立增量的性质相符合, 也有利于多相关性能退化数据的建模分析。

(3) 基于 Copula 函数的多相关性能退化模型

综合以上对 d 维性能退化过程的边缘退化过程以及相关关系的建模描述, 可得基于 Copula 函数的多相关性能退化模型描述为:

$$\begin{aligned} Y_k(t_j) &= \sum_{l=2}^j \Delta Y_{kl}, k=1, \dots, d, j=2, \dots, m, \\ \Delta Y_{kl} &\sim N(\eta_k(t_l - t_{l-1}), \sigma_k^2(t_l - t_{l-1})), k \in [1, h]^+, \\ \Delta Y_{kl} &\sim IG(\Delta \Lambda_k(t_l), \lambda_k \Delta \Lambda_k(t_l)^2), k \in [h+1, d]^+, \\ F(\Delta Y_1, \dots, \Delta Y_d) &= C(F_1(\Delta Y_1), \dots, F_d(\Delta Y_d)) \end{aligned} \quad (5-8)$$

其中, m 为 d 个性能退化过程共同的观测次数, $[1, h]^+$ 为 1 到 h 的整数集合。

式(5-8)中模型建立的基本思路可描述为：模型各边缘性能退化过程都是建立在对应退化增量之上，而各退化增量则由对应的基础性能退化过程的增量模型描述；多性能退化过程的相关关系则是通过 Copula 函数对多退化增量的相关关系的建模来实现的。该多相关性能退化模型一方面包含了边缘退化过程的模型，另一方面通过 Copula 函数建立了多性能退化过程相关关系的模型。在该模型的基础上，通过采用不同的 Copula 函数即可建立不同相关关系下的多性能退化过程模型，并且可进一步完成考虑环境与工作应力因素影响的多性能退化过程建模。

5.3.3 考虑动态环境与任务的多性能退化建模

重型数控机床的动态环境与任务信息主要包括机床所处的工作环境信息和机床所经历的工作任务信息。令 \mathbf{X}^E 和 \mathbf{X}^O 分别描述机床环境与任务信息中的环境变量和任务变量。 \mathbf{X}^E 和 \mathbf{X}^O 本质上都是影响机床性能退化的外部因素，对于重型数控机床而言考虑到机床结构的庞大、功能的多样，机床所处的工作环境和所经历的工作任务往往具有明显的特性： \mathbf{X}^E 主要用于描述厂房环境条件，对于同一厂房条件下的多个重型数控机床，其环境变量往往处于比较稳定的状态，即 \mathbf{X}^E 多以常量的形式表现；而 \mathbf{X}^O 主要用于描述机床所经历的工作任务，对于同一机床在不同的任务时间所承担的任务往往存在一定的差别，对于同型号的不同机床其所承担的任务更是存在显著的差别，并且随着任务时间的不同存在着动态变化的特性。考虑到重型数控机床工作环境与工作任务的特性，本文着重将环境和任务两个外部影响因素分开来进行建模描述，以实现机床状态监测数据进行准确的建模，并对机床的可靠性根据其环境与任务进行精确的评估。

环境和任务等外部因素对性能退化过程的影响，可以通过对上文给出的基础性能退化模型进行适当的模型拓展予以实现。根据式(5-1)和(5-3)所示基础性能退化模型的性质，可以将 \mathbf{X}^E 和 \mathbf{X}^O 通过维纳过程模型的退化速率参数和逆高斯过程模型的退化均值函数建模引入，从而构建考虑环境和任务变量的性能退化过程模型：

$$Y_k(t) = \eta_k(\mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\eta,k})t + \sigma_k B(t), k \in [1, h]^+ \quad (5-9)$$

$$Y_k(t) \sim \text{IG}\left(\Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k}), \lambda_k \Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k})^2\right), k \in [h+1, d]^+ \quad (5-10)$$

式中， $\boldsymbol{\theta}_{\eta,k} = \{\boldsymbol{\theta}_{\eta,k}^F, \boldsymbol{\theta}_{\eta,k}^R\}$ ， $\boldsymbol{\theta}_{\Lambda,k} = \{\boldsymbol{\theta}_{\Lambda,k}^F, \boldsymbol{\theta}_{\Lambda,k}^R\}$ ， $\boldsymbol{\theta}_k^F$ 和 $\boldsymbol{\theta}_k^R$ 分别对应于第 k 个性能退化过程模型的固定参数和随机参数；固定参数是指模型参数中不随着机床个体变化而变化的模型参数，随机参数为描述机床个体差异性的参数，即上述章节中随机效应模型的模型参数。

\mathbf{X}^E 和 \mathbf{X}^O 的引入分别通过维纳过程模型的退化速率参数 $\eta_k(\mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\eta,k})$ 和逆高斯过程模型的均值函数 $\Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k})$ 来实现。本文采用这样的引入方式是考虑到环境和任务因素主要影响退化过程的轨迹形式，并且在具体建模时可以借鉴现有加速性能退化模型的研究。此时，可以将 \mathbf{X}^E 和 \mathbf{X}^O 看作基础性能退化模型的加速应力，将 $\eta_k(\mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\eta,k})$ 和 $\Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k})$ 看作是引入加速应力后的模型参数和均值函数。加速应力的引入主要包括以下方式^[87]：

1) 线性关系

$$h(x) = \theta_0 + \theta_1 x \quad (5-11)$$

2) 幂率关系

$$h(x) = \theta_0 x^{\theta_1} \quad (5-12)$$

3) 指数关系

$$h(x) = \theta_0 e^{\theta_1 x} \quad (5-13)$$

4) Arrhenius 关系

$$h(x) = \theta_0 e^{-\theta_1/s} \quad (5-14)$$

5) Inverse-logit 函数关系

$$h(x) = \theta_0 + \theta_1 e^s / (1 + e^s) \quad (5-15)$$

式中， x 代表广义的加速应力变量，对应于 \mathbf{X}^E 和 \mathbf{X}^O 中的应力变量； $h(x)$ 代表广义的引入加速应力变量之后的模型参数，对应于退化速率参数 $\eta_k(\mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\eta,k})$ 和退化均值函数 $\Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k})$ ； θ_0 和 θ_1 代表广义的模型参数，即对应包含于 $\boldsymbol{\theta}_{\eta,k}^F, \boldsymbol{\theta}_{\eta,k}^R$ 和 $\boldsymbol{\theta}_{\Lambda,k}^F, \boldsymbol{\theta}_{\Lambda,k}^R$ 。

在实际的建模过程中，可以根据环境和任务变量对各性能退化过程的影响机理，从式(5-11)至(5-15)中选择适当的函数关系来将环境与任务变量引入到性能退化过程模型中去。进一步，根据式(5-9)和(5-10)所示的考虑环境和任务变量的性能退化过程模型，可以得到对应模型下的退化增量分别为：

$$\Delta Y_k \sim N(\eta_k(\mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\eta,k}) \Delta t, \sigma_k^2 \Delta t), k \in [1, h]^+ \quad (5-16)$$

$$\Delta Y_k \sim IG(\Delta \Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k}), \lambda_k \Delta \Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k})^2), k \in [h+1, d]^+ \quad (5-17)$$

$$\Delta \Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k}) = \Lambda_k(t + \Delta t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k}) - \Lambda_k(t, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k})$$

用这些边缘退化过程的退化增量模型替换式(5-8)中的退化增量模型即可得到

考虑环境和工况变量的多性能退化过程模型为：

$$\begin{aligned}
 Y_k(t_j) &= \sum_{l=2}^j \Delta Y_{kl}, k=1, \dots, d, j=2, \dots, m, \\
 \Delta Y_{kl} &\sim N\left(\eta_k(\mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\eta,k})(t_l - t_{l-1}), \sigma_k^2(t_l - t_{l-1})\right), k \in [1, h]^+, \\
 \Delta Y_{kl} &\sim \text{IG}\left(\Delta \Lambda_k(t_l, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k}), \lambda_k \Delta \Lambda_k(t_l, \mathbf{X}^E, \mathbf{X}^O; \boldsymbol{\theta}_{\Lambda,k})^2\right), k \in [h+1, d]^+, \\
 F(\Delta Y_{1l}, \dots, \Delta Y_{kl}, \dots, \Delta Y_{dl}) &= C(F_1(\Delta Y_{1l}), \dots, F_k(\Delta Y_{kl}), \dots, F_d(\Delta Y_{dl}); \boldsymbol{\theta}_C)
 \end{aligned} \tag{5-18}$$

根据性能退化过程与机床寿命之间的关系，对于具有多性能退化的机床，令 D_1, D_2, \dots, D_d 分别为机床 d 个性能退化过程所对应的退化阈值。进一步假设当任何一个性能退化指标超出给定的阈值时机床发生故障，即 d 个性能退化过程对于机床的故障而言具有相互竞争的关系。此时，机床在某一时刻的可靠度定义为：

$$R(t) = \Pr\left(\sup_{\tau \leq t} Y_1(\tau) \leq D_1, \sup_{\tau \leq t} Y_2(\tau) \leq D_2, \dots, \sup_{\tau \leq t} Y_d(\tau) \leq D_d\right) \tag{5-19}$$

当对机床的状态监测持续到时间点 t_m ，获得每一个性能退化过程在该时刻点的性能退化观测值，若机床没有发生故障则机床的剩余寿命 T^{RUL} 可以定义为：

$$T^{RUL} = \inf \left\{ r : \begin{array}{l} Y_1(t_m + r) > D_1, \text{ or } \dots, \text{ or } Y_d(t_m + r) > D_d \\ | Y_1(t_m) < D_1, \text{ and } \dots, \text{ and } Y_d(t_m) < D_d \end{array} \right\} \tag{5-20}$$

5.4 基于状态监测数据的重型数控机床可靠性评估

在考虑动态环境与任务的多性能退化模型的基础上，本节将针对不完全状态监测数据下重型数控机床可靠性评估的问题，着重研究基于贝叶斯方法的状态监测数据分析、性能退化预计和机床可靠性评估的方法。首先构建基于贝叶斯方法的多性能退化分析的基本框架，然后在该框架下研究突破不完全观测数据下模型参数的估计、性能退化的预测以及机床可靠性评估和剩余寿命评估的求解实现。

5.4.1 基于贝叶斯方法的多性能退化分析的基本框架

重型数控机床基于贝叶斯方法的多性能退化分析的基本框架如图 5-3 所示。该框架主要包括三大部分：1) 边缘退化过程模型参数的估计；2) Copula 函数模型参数的估计；3) 基于数值积分的退化分析与可靠性评估。

该框架的关键要点在于利用建立在 Copula 函数上的多性能退化模型的性质：多性能退化过程中的边缘退化过程可以与多性能退化过程之间的相关关系相分离，并通过边缘退化过程的模型进行描述；并且边缘性能退化过程的模型参数与相关关系模型（Copula 函数）的参数之间不存在耦合，两者可以分别进行估计。

因此，在该框架下首先利用状态监测数据对各边缘退化过程模型参数进行估计；然后在模型参数估计的条件下获得边缘退化过程增量的累积概率分布值并作为 Copula 函数参数估计的输入，来对相关关系模型参数进行估计；最后在所有模型参数估计的基础上，应用基于数值积分的退化分析与可靠性评估方法，完成缺失观测点和未来观测点性能退化的预测以及机床剩余寿命的评估。

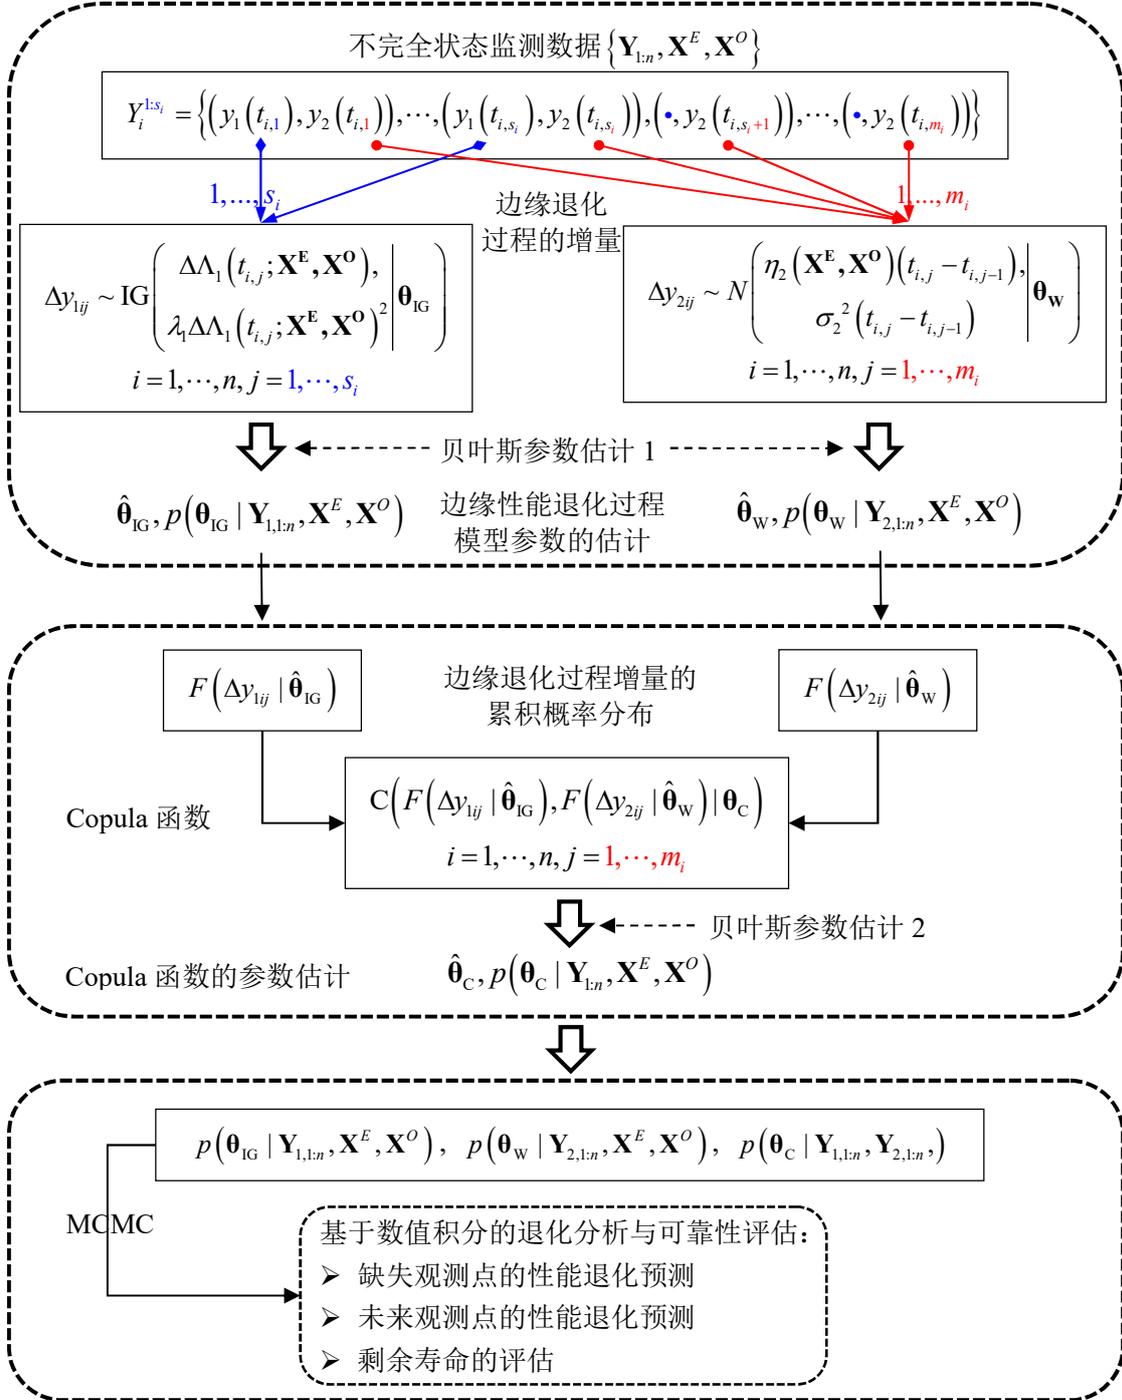


图 5-3 基于贝叶斯方法的多性能退化分析的基本框架

本文采用存在尾部观测点缺失的两维性能退化数据，来对基于状态监测数据的重型数控机床可靠性评估方法进行描述。该不完全状态监测数据为对某批次 n 台机床的性能指标 $Y_1(t)$ 和 $Y_2(t)$ 以及工作环境 X^E 和工作任务 X^O 进行监测获得状态监测数据集。对于第 i 台机床 ($i=1, \dots, n$) 在 m_i 个不同的观测时间点 t_{ij} ($j=1, \dots, m_i$) 对其性能指标和环境与工作应力变量进行监测。由于受到监测设备、人员和技术等的影响，对于性能指标 $Y_1(t)$ 只获得了初始的 s_i 个观测值而尾部的 $m_i - s_i$ 个观测值缺失；对于性能指标 $Y_2(t)$ 、环境变量 X^E 和工作任务变量 X^O 则获得了完整的观测数据。不完全状态监测数据可以表示为 $\{\mathbf{Y}_{1:n}, \mathbf{X}^E, \mathbf{X}^O\}$ ($\mathbf{Y}_{1:n} = \{Y_i^{1:s_i}, i=1, \dots, n\}$)，其中的性能退化观测数据 $Y_i^{1:s_i}$ 可以进一步表示为：

$$Y_i^{1:s_i} = \left\{ \left(y_1(t_{i,1}), y_2(t_{i,1}) \right), \dots, \left(y_1(t_{i,s_i}), y_2(t_{i,s_i}) \right), \left(\bullet, y_2(t_{i,s_i+1}) \right), \dots, \left(\bullet, y_2(t_{i,m_i+1}) \right) \right\} \quad (5-21)$$

式中， $\left(\bullet, y_2(t_{i,s_i+1}) \right)$ 表示在 t_{i,s_i+1} 时刻 $Y_1(t)$ 的观测值缺失。

该不完全状态监测数据主要是由于性能退化监测中存在尾部监测点缺失所形成的，选择这类不完全状态监测数据是出于以下考虑：在实际工程中尾部监测点的缺失将会直接影响到基于性能退化分析的可靠性评估和剩余寿命预测，这是因为机床的性能退化预测、首次穿越时间点的计算都依赖于尾部监测点的观测值；而对于其他类型的缺失数据，如起始监测点和中间监测点的缺失，由于其对性能退化预测和可靠性评估的影响较小，并且在数据分析中可以将这些点进行剔除后转换成完全监测数据进行分析处理。

5.4.2 多性能退化分析的数学表达

对于不完全状态监测数据 $\{\mathbf{Y}_{1:n}, \mathbf{X}^E, \mathbf{X}^O\}$ ，根据图 5-3 所示的基于贝叶斯方法的分析框架，首先分别对性能退化过程 $Y_1(t)$ 和 $Y_2(t)$ 进行边缘退化过程的分析并对各退化过程对应的模型参数进行估计。根据式(5-18)所示的多性能退化过程模型，多性能退化过程模型的边缘退化过程可分别用维纳过程模型和逆高斯过程模型进行建模。下面以逆高斯过程模型来描述存在尾部观测点的性能退化过程 $Y_1(t)$ ，以维纳过程模型来描述性能退化过程 $Y_2(t)$ ，在此基础上对基于贝叶斯方法的多性能退化分析方法进行描述。

(1) 边缘性能退化过程 $Y_1(t)$ 的退化数据分析

对于不完全状态监测数据中 $Y_1(t)$ 的观测数据 $\mathbf{Y}_{1,1:n} = \{y_1^{1:s_i}, i=1, \dots, n\}$ 且其中 $y_1^{1:s_i} = \{y_1(t_{i,1}), \dots, y_1(t_{i,s_i})\}$ ，根据式(5-10)所示的考虑环境和任务变量的逆高斯过程模型，可将 $\mathbf{Y}_{1,1:n}$ 所包含的信息通过似然函数描述为：

$$\begin{aligned}
 & L(\mathbf{Y}_{1,1:n}, \boldsymbol{\theta}_{IG}^R | \mathbf{X}^E, \mathbf{X}^O, \boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H) \\
 &= \prod_{i=1}^n g(\boldsymbol{\theta}_{\Lambda,i}^R | \boldsymbol{\theta}_{IG}^H) \prod_{j=2}^{s_i} f_{IG}(\Delta y_1(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{\Lambda,i}^R) \\
 &= \prod_{i=1}^n g(\boldsymbol{\theta}_{\Lambda,i}^R | \boldsymbol{\theta}_{IG}^H) \prod_{j=2}^{s_i} \sqrt{\frac{\lambda_1 \Delta \Lambda_1(t_{i,j})^2}{2\pi \Delta y_1(t_{i,j})^3}} \exp\left(-\frac{\lambda_1 (\Delta y_1(t_{i,j}) - \Delta \Lambda_1(t_{i,j}))^2}{2\Delta y_1(t_{i,j})}\right)
 \end{aligned} \tag{5-22}$$

式中, $\Delta \Lambda_1(t_{i,j}) = \Lambda_1(t_{i,j} | x_{i,j}^E, x_{i,j}^O, \boldsymbol{\theta}_{\Lambda}^F, \boldsymbol{\theta}_{\Lambda,i}^R) - \Lambda_1(t_{i,j-1} | x_{i,j-1}^E, x_{i,j-1}^O, \boldsymbol{\theta}_{\Lambda}^F, \boldsymbol{\theta}_{\Lambda,i}^R)$ 为逆高斯过程模型均值函数的增量, 其中均值函数可根据环境和任务变量对性能退化过程的影响关系从式(5-11)至(5-15)中选择确定; $\Delta y_1(t_{i,j}) = y_1(t_{i,j}) - y_1(t_{i,j-1})$ 为性能退化数据的增量, $\boldsymbol{\theta}_{IG}^F = \{\lambda_1, \boldsymbol{\theta}_{\Lambda}^F\}$ 为逆高斯过程模型中的固定参数, $\boldsymbol{\theta}_{IG}^R = \{\boldsymbol{\theta}_{\Lambda,1}^R, \dots, \boldsymbol{\theta}_{\Lambda,n}^R\}$ 为模型中的随机参数, $\boldsymbol{\theta}_{IG}^H$ 是随机参数概率分布模型中的超参数。

根据第四章中所建立的基于贝叶斯方法的逆高斯过程性能退化分析方法, 当获得模型参数 $\boldsymbol{\theta}_{IG}^F$ 和 $\boldsymbol{\theta}_{IG}^H$ 的先验分布之后, 可以应用贝叶斯方法构建性能退化数据 $\mathbf{Y}_{1,1:n}$ 分析的表达式:

$$\begin{aligned}
 & p(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^R, \boldsymbol{\theta}_{IG}^H | \mathbf{Y}_{1,1:n}, \mathbf{X}^E, \mathbf{X}^O) \\
 &= \frac{\pi(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H) L(\mathbf{Y}_{1,1:n}, \boldsymbol{\theta}_{IG}^R | \mathbf{X}^E, \mathbf{X}^O, \boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H)}{\int_{\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H} \pi(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H) L(\mathbf{Y}_{1,1:n}, \boldsymbol{\theta}_{IG}^R | \mathbf{X}^E, \mathbf{X}^O, \boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H) d\boldsymbol{\theta}_{IG}^F d\boldsymbol{\theta}_{IG}^H} \\
 &\propto \pi(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H) \prod_{i=1}^n g(\boldsymbol{\theta}_{\Lambda,i}^R | \boldsymbol{\theta}_{IG}^H) \prod_{j=2}^{s_i} \sqrt{\lambda_1} \Delta \Lambda_1(t_{i,j}) \exp\left(-\frac{\lambda_1 (\Delta y_1(t_{i,j}) - \Delta \Lambda_1(t_{i,j}))^2}{2\Delta y_1(t_{i,j})}\right)
 \end{aligned} \tag{5-23}$$

式中, $\pi(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^H)$ 为模型参数 $\boldsymbol{\theta}_{IG}^F$ 和 $\boldsymbol{\theta}_{IG}^H$ 的先验分布, 可以根据 4.4.1 节中描述的性能退化模型参数先验分布获取的方法来得到; $p(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^R, \boldsymbol{\theta}_{IG}^H | \mathbf{Y}_{1,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 为模型参数 $\boldsymbol{\theta}_{IG}^F$, $\boldsymbol{\theta}_{IG}^R$ 和 $\boldsymbol{\theta}_{IG}^H$ 的联合后验分布。

对于后验分布 $p(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{IG}^R, \boldsymbol{\theta}_{IG}^H | \mathbf{Y}_{1,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 的求解, 可以采用 4.4.3 节中描述的基于 MCMC 的参数后验分布抽样的方法, 通过 OpenBUGS 软件来实现对模型参数的抽样, 并基于后验分布的样本获取模型参数的估计。

(2) 边缘性能退化过程 $Y_2(t)$ 的退化数据分析

对于状态监测数据 $\mathbf{Y}_{2,1:n} = \{\mathbf{y}_2^{1:m_i}, i=1, \dots, n\}$ 且其中 $\mathbf{y}_2^{1:m_i} = \{y_2(t_{i,1}), \dots, y_2(t_{i,m_i})\}$, 根据式(5-9)所示的考虑环境与任务变量的维纳过程模型, 可将 $\mathbf{y}_2^{1:m_i}$ 所包含的信息通过似然函数描述为:

$$\begin{aligned}
 & L(\mathbf{Y}_{2,1:n}, \boldsymbol{\theta}_W^R | \mathbf{X}^E, \mathbf{X}^O, \boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H) \\
 &= \prod_{i=1}^n g(\boldsymbol{\theta}_{\eta,i}^R | \boldsymbol{\theta}_W^H) \prod_{j=2}^{m_i} f_W(\Delta y_2(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \boldsymbol{\theta}_\eta^F, \boldsymbol{\theta}_{\eta,i}^R) \\
 &= \prod_{i=1}^n g(\boldsymbol{\theta}_{\eta,i}^R | \boldsymbol{\theta}_{IG}^H) \prod_{j=2}^{m_i} \phi\left(\frac{\Delta y_2(t_{i,j}) - \eta_2(x_{i,j}^E, x_{i,j}^O, \boldsymbol{\theta}_\eta^F, \boldsymbol{\theta}_{\eta,i}^R)(t_{i,j} - t_{i,j-1})}{\sigma_2 \sqrt{t_{i,j} - t_{i,j-1}}}\right)
 \end{aligned} \tag{5-24}$$

式中， $\Delta y_2(t_{i,j}) = y_2(t_{i,j}) - y_2(t_{i,j-1})$ 为性能退化数据的增量； $\eta_2(x_{i,j}^E, x_{i,j}^O, \boldsymbol{\theta}_\eta^F, \boldsymbol{\theta}_{\eta,i}^R)$ 为维纳过程模型中退化速率函数，根据环境与任务变量对性能退化过程的影响关系从式(5-11)至(5-15)中选择确定； $\boldsymbol{\theta}_W^F = \{\sigma_2, \boldsymbol{\theta}_\eta^F\}$ 为固定参数， $\boldsymbol{\theta}_W^R = \{\boldsymbol{\theta}_{\eta,1}^R, \dots, \boldsymbol{\theta}_{\eta,n}^R\}$ 为随机参数， $\boldsymbol{\theta}_W^H$ 是随机参数概率分布模型中的超参数。

与 $\mathbf{Y}_{1,1:n}$ 的分析类似，对于性能退化数据 $\mathbf{Y}_{2,1:n}$ ，当获得模型参数 $\boldsymbol{\theta}_W^F$ 和 $\boldsymbol{\theta}_{IG}^H$ 的先验分布之后，应用贝叶斯方法构建性能退化数据 $\mathbf{Y}_{2,1:n}$ 分析的表达式：

$$\begin{aligned}
 & p(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R, \boldsymbol{\theta}_W^H | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O) \\
 &= \frac{\pi(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H) L(\mathbf{Y}_{2,1:n}, \boldsymbol{\theta}_W^R | \mathbf{X}^E, \mathbf{X}^O, \boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H)}{\int_{\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H} \pi(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H) L(\mathbf{Y}_{2,1:n}, \boldsymbol{\theta}_W^R | \mathbf{X}^E, \mathbf{X}^O, \boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H) d\boldsymbol{\theta}_W^F d\boldsymbol{\theta}_W^H} \\
 &\propto \pi(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H) \prod_{i=1}^n g(\boldsymbol{\theta}_{\eta,i}^R | \boldsymbol{\theta}_{IG}^H) \prod_{j=2}^{m_i} \phi\left(\frac{\Delta y_2(t_{i,j}) - \eta_2(x_{i,j}^E, x_{i,j}^O, \boldsymbol{\theta}_\eta^F, \boldsymbol{\theta}_{\eta,i}^R)(t_{i,j} - t_{i,j-1})}{\sigma_2 \sqrt{t_{i,j} - t_{i,j-1}}}\right)
 \end{aligned} \tag{5-25}$$

式中， $\pi(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^H)$ 为模型参数 $\boldsymbol{\theta}_W^F$ 和 $\boldsymbol{\theta}_{IG}^H$ 的先验分布，可以根据 4.4.1 节中描述的参数先验分布获取的方法来得到； $p(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R, \boldsymbol{\theta}_W^H | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 为模型参数 $\boldsymbol{\theta}_W^F$ ， $\boldsymbol{\theta}_W^R$ 和 $\boldsymbol{\theta}_W^H$ 的联合后验分布。

对于后验分布 $p(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R, \boldsymbol{\theta}_W^H | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 的求解，可以采用 4.4.3 节中描述的基于 MCMC 的参数后验分布抽样的方法，通过 OpenBUGS 软件来实现对模型参数的抽样，并基于后验分布的样本获取模型参数的估计。

(3) 基于 Copula 函数的多性能退化数据的相关关系分析

根据图 5-3 所示的基本框架，当获得边缘退化过程模型的参数估计之后，可以进一步在模型参数的基础上得到相应退化增量的累积概率分布函数的取值，分别表示如下：

$$\begin{aligned}
 F(\Delta y_1(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \hat{\boldsymbol{\theta}}_{IG}^F, \hat{\boldsymbol{\theta}}_{\Lambda,i}^R) &= \Phi\left(\frac{\hat{\lambda}_1}{\sqrt{\Delta y_{1ij}}} (\Delta y_1(t_{i,j}) - \Delta \hat{\Lambda}_1(t_{i,j}))\right) + \\
 &\exp\left(\frac{2\hat{\lambda}_1}{\Delta \hat{\Lambda}_1(t_{i,j})}\right) \Phi\left(-\frac{\hat{\lambda}_1}{\sqrt{\Delta y_{1ij}}} (\Delta y_1(t_{i,j}) + \Delta \hat{\Lambda}_1(t_{i,j}))\right)
 \end{aligned} \tag{5-26}$$

$$F(\Delta y_2(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \hat{\theta}_w^F, \hat{\theta}_{\eta,i}^R) = \Phi \left(\frac{\Delta y_2(t_{i,j}) - \eta_2(x_{i,j}^E, x_{i,j}^O, \hat{\theta}_w^F, \hat{\theta}_{\eta,i}^R)(t_{i,j} - t_{i,j-1})}{\sigma_2 \sqrt{t_{i,j} - t_{i,j-1}}} \right) \quad (5-27)$$

式中, $\hat{\theta}_{IG}^F$ 和 $\hat{\theta}_{\Lambda,i}^R$ 为逆高斯过程模型参数根据后验分布 $p(\theta_{IG}^F, \theta_{IG}^R, \theta_{IG}^H | \mathbf{Y}_{1,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 所获得的点估计值, $\Delta \hat{\Lambda}_1(t_{i,j}) = \Lambda_1(t_{i,j} | x_{i,j}^E, x_{i,j}^O, \hat{\theta}_{IG}^F, \hat{\theta}_{\Lambda,i}^R) - \Lambda_1(t_{i,j-1} | x_{i,j}^E, x_{i,j}^O, \hat{\theta}_{IG}^F, \hat{\theta}_{\Lambda,i}^R)$ 为逆高斯过程模型在给定相应参数点估计值下的均值函数的增量, $\hat{\theta}_w^F$ 和 $\hat{\theta}_{\eta,i}^R$ 为维纳过程模型参数根据后验分布 $p(\theta_w^F, \theta_w^R, \theta_w^H | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 所获得的点估计值。

此时, $Y_1(t)$ 和 $Y_2(t)$ 在相同观测时间间隔上的退化增量对 $(\Delta y_1(t_{i,j}), \Delta y_2(t_{i,j}))$ 所对应的 $(F(\Delta y_1(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \hat{\theta}_{IG}^F, \hat{\theta}_{\Lambda,i}^R), F(\Delta y_2(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \hat{\theta}_w^F, \hat{\theta}_{\eta,i}^R))$ ($k=1, \dots, n$, $j=2, \dots, s_i$), 其本质上为多性能退化过程模型中 Copula 函数的样本。根据图 5-3 所示的框架以及式(5-18)所示模型的性质, 退化过程之间相关关系的信息可通过 Copula 函数的概率密度函数所构成的似然函数描述为:

$$\begin{aligned} L(\mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n} | \theta_c) &= \prod_{i=1}^n \prod_{j=2}^{s_i} c(\hat{u}_{i,j}, \hat{v}_{i,j} | \theta_c) \\ \hat{u}_{i,j} &= F(\Delta y_1(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \hat{\theta}_{IG}^F, \hat{\theta}_{\Lambda,k}^R), \\ \hat{v}_{i,j} &= F(\Delta y_2(t_{i,j}) | x_{i,j}^E, x_{i,j}^O, \hat{\theta}_w^F, \hat{\theta}_{\eta,k}^R), \\ c(\hat{u}_{i,j}, \hat{v}_{i,j} | \theta_c) &= \frac{\partial^2 C(\hat{u}_{i,j}, \hat{v}_{i,j} | \theta_c)}{\partial \hat{u}_{i,j} \partial \hat{v}_{i,j}} \end{aligned} \quad (5-28)$$

式中, $c(\hat{u}_{i,j}, \hat{v}_{i,j} | \theta_c)$ 为 Copula 函数的概率密度函数。

当获得模型参数 θ_c 的先验分布之后, 应用贝叶斯方法构建多性能退化过程相关关系分析的表达式:

$$\begin{aligned} p(\theta_c | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n}) &= \frac{\pi(\theta_c) L(\theta_c | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n})}{\int_{\theta_c} \pi(\theta_c) L(\theta_c | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n}) d\theta_c} \\ &\propto \pi(\theta_c) \prod_{i=1}^n \prod_{j=2}^{s_i} c(\hat{u}_{i,j}, \hat{v}_{i,j} | \theta_c) \end{aligned} \quad (5-29)$$

式中, $\pi(\theta_c)$ 和 $p(\theta_c | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n})$ 分别为模型参数 θ_c 的先验分布和后验分布。

对于后验分布 $p(\theta_c | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n})$ 的求解, 可以采用基于 MCMC 的参数后验分布抽样的方法, 通过 OpenBUGS 软件来实现对模型参数的抽样, 并基于后验分布的样本获取模型参数的估计。

至此, 根据机床的状态监测数据 $\{\mathbf{Y}_{1:n}, \mathbf{X}^E, \mathbf{X}^O\}$, 基于贝叶斯方法逐步对边缘性能退化数据和多性能退化数据的相关关系进行分析, 得到了多性能退化模型参数的估计。此时, 状态监测数据所包含的信息被量化为多性能退化模型参数的后验

分布，这为后续的可靠性评估和剩余寿命预测提供了基础。

5.4.3 数据缺失情形下基于状态监测数据的可靠性评估

根据图 5-3 所示的框架，当获得多性能退化模型参数的后验分布后，即可根据所建立的考虑环境与任务影响的多性能退化过程模型来对缺失观测点和未来观测点的性能退化进行预计、对机床的可靠性和剩余寿命进行评估。

(1) 缺失观测时间点性能退化数据的预测

对于性能退化数据 $(\bullet, y_2(t_{i,p_i}))$ ($p_i = s_i + 1, \dots, m_i$) 中缺失观测时间点性能退化数据的预测，需要借助于多性能退化过程相关关系的 Copula 模型，从第一个缺失的观测时间点 t_{i,p_i+1} 开始依次对缺失的观测数据进行预测。对于 $y_1(t_{i,p_i})$ 的预测，需要利用同一时刻观测得到的性能退化数据 $y_2(t_{i,p_i})$ 及多性能退化之间的相关关系来对缺失的数据进行预测。由 $y_2(t_{i,p_i+1})$ 及 $y_2(t_{i,p_i})$ 可以得到观测时间区间 $[t_{i,p_i-1}, t_{i,p_i}]$ 性能退化过程 $Y_2(t)$ 的退化增量 $\Delta y_2(t_{i,p_i})$ ，结合 $Y_2(t)$ 对应性能退化过程模型的参数估计 $p(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R, \boldsymbol{\theta}_W^H | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 以及该模型下退化增量的分布情况，可以得到退化增量 $\Delta y_2(t_{i,p_i})$ 的累积概率分布函数的取值为：

$$\begin{aligned} & F(\Delta y_2(t_{i,p_i}) | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O) \\ &= \int_{\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R} \left(F(\Delta y_2(t_{i,p_i}) | x_{i,p_i}^E, x_{i,p_i}^O, \boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R) \times \right. \\ & \quad \left. p(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O) \right) d\boldsymbol{\theta}_W^F d\boldsymbol{\theta}_W^R \quad (5-30) \\ &= \int_{\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R} \left(\Phi \left(\frac{\Delta y_2(t_{i,p_i}) - \eta_2(x_{i,p_i}^E, x_{i,p_i}^O, \boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R)(t_{i,p_i} - t_{i,p_i-1})}{\sigma_2 \sqrt{t_{i,p_i} - t_{i,p_i-1}}} \right) \times \right. \\ & \quad \left. p(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O) \right) d\boldsymbol{\theta}_W^F d\boldsymbol{\theta}_W^R \end{aligned}$$

进一步根据式(5-18)中描述的性能退化过程 $Y_1(t)$ 和 $Y_2(t)$ 在观测时间区间 $[t_{i,p_i-1}, t_{i,p_i}]$ 上对应退化增量 $\Delta y_1(t_{i,p_i})$ 和 $\Delta y_2(t_{i,p_i})$ 的累积概率分布函数取值之间的关系，可以得到给定 $F(\Delta y_2(t_{i,p_i}) | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 的条件下退化增量 $\Delta y_1(t_{i,p_i})$ 对应 $F(\Delta y_1(t_{i,p_i}) | x_{i,p_i}^E, x_{i,p_i}^O, \boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{\Lambda,i}^R)$ 的累积概率分布函数的取值为：

$$\begin{aligned} & F(u_{i,p_i} | v_{i,p_i}, \mathbf{Y}_{1:n}, \mathbf{X}^E, \mathbf{X}^O) = C(u_{i,p_i} | v_{i,p_i}, \mathbf{Y}_{1:n}, \mathbf{X}^E, \mathbf{X}^O) \\ &= \int_{\boldsymbol{\theta}_C} \frac{\partial C(u_{i,p_i}, v_{i,p_i} | \boldsymbol{\theta}_C)}{\partial v_{i,p_i}} p(\boldsymbol{\theta}_C | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n}) d\boldsymbol{\theta}_C, \quad (5-31) \\ & u_{i,p_i} = F(\Delta y_1(t_{i,p_i}) | x_{i,p_i}^E, x_{i,p_i}^O, \boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{\Lambda,i}^R), \\ & v_{i,p_i} = F(\Delta y_2(t_{i,p_i}) | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O) \end{aligned}$$

对于 $F(u_{i,p_i} | v_{i,p_i}, \mathbf{Y}_{1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 进行抽样即可获得退化增量 $\Delta y_1(t_{i,p_i})$ 的累积概率

在此基础上计算式(5-30)中的 $F(\Delta y_2(t_{i,p_i}) | x_{i,p_i}^E, x_{i,p_i}^O, \hat{\theta}_W^F, \hat{\theta}_{\eta,i}^R)$ ，式(5-31)中的 $C(u_{i,p_i} | v_{i,p_i}, \hat{\theta}_C)$ 以及式(5-32)中的 $F^{-1}(u_{i,p_i} | x_{i,p_i}^E, x_{i,p_i}^O, \hat{\theta}_{IG}^F, \hat{\theta}_{\Lambda,i}^R)$ ；与此同时通过条件 Copula 函数所描述的退化增量的累积概率分布函数取值之间的关系来将所有的计算联系起来，从而完成由式(5-30)至(5-32)的计算实现。

(2) 未来观测时间点性能退化数据的预测

对于未来观测时间点 $t_{i,q_i}, q_i = m_i + 1, \dots, M_i$ 对应性能退化的预测，需要借助于多性能退化过程模型中性能退化增量相关关系的 Copula 模型，从未来第一个观测时间点 t_{k,q_k+1} 开始依次对未来的观测数据进行预测。不同于缺失观测时间点性能退化数据的预测，未来观测时间点的预测需要完全依赖于模型参数的后验分布。根据式(5-18)中所描述的多性能退化过程模型可知：对未来某一时间点的性能退化的预测，需要获得这一时间点与上一次观测时间点之间的退化增量；对于不同边缘退化过程的退化增量分别服从不同的分布，并且这些退化增量的累积概率分布函数取值的关联关系是通过 Copula 函数来建立的。因此，可以通过对 Copula 函数来进行抽样，获得各边缘退化过程对应退化增量的累积概率分布函数的取值，并利用各边缘退化过程对应退化增量的概率分布来获得退化增量的值，以此结合上一次观测点时间点的退化值来获得需要预测的未来观测时间点的性能退化值。

基于 Copula 函数所描述的退化增量相关关系的模型，以及模型参数后验分布 $p(\theta_C | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n})$ ，可以得到：

$$\begin{aligned} F(u_{i,q_i}, v_{i,q_i} | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n}) &= C(u_{i,q_i}, v_{i,q_i} | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n}) \\ &= \int_{\theta_C} C(u_{i,q_i}, v_{i,q_i} | \theta_C) p(\theta_C | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n}) d\theta_C \end{aligned} \quad (5-33)$$

式中， u_{i,q_i} 和 v_{i,q_i} 对应于退化增量 $\Delta y_1(t_{i,q_i})$ 和 $\Delta y_2(t_{i,q_i})$ 的累积概率分布函数的取值。

在获得 u_{i,q_i} 和 v_{i,q_i} 的基础上，利用多性能退化过程模型中各边缘退化过程对应退化增量的概率分布模型，可以得到 u_{i,q_i} 和 v_{i,q_i} 对应边缘退化过程的退化增量：

$$\begin{aligned} y_1(t_{i,q_i}) &= y_1(t_{i,q_i-1}) + \Delta y_1(t_{i,q_i}), \\ y_2(t_{i,q_i}) &= y_2(t_{i,q_i-1}) + \Delta y_2(t_{i,q_i}), \\ \Delta y_1(t_{i,q_i}) &= \int_{\theta_{IG}^F, \theta_{\Lambda,i}^R} \left(F^{-1}(u_{i,q_i} | x_{i,q_i}^E, x_{i,q_i}^O, \theta_{IG}^F, \theta_{\Lambda,i}^R) \times \right. \\ &\quad \left. p(\theta_{IG}^F, \theta_{\Lambda,i}^R | \mathbf{Y}_{1,1:n}, \mathbf{X}^E, \mathbf{X}^O) \right) d\theta_{IG}^F d\theta_{\Lambda,i}^R, \\ \Delta y_2(t_{i,q_i}) &= \int_{\theta_W^F, \theta_{\eta,i}^R} \left(F^{-1}(v_{i,q_i} | x_{i,q_i}^E, x_{i,q_i}^O, \theta_W^F, \theta_{\eta,i}^R) \times \right. \\ &\quad \left. p(\theta_W^F, \theta_{\eta,i}^R | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O) \right) d\theta_W^F d\theta_{\eta,i}^R \end{aligned} \quad (5-34)$$

对于式(5-33)至(5-34)的计算需要采用基于数值积分的方法来实现，其计算流程如图 5-4 所示。该算法的核心在于利用模型参数后验分布 $p(\theta_C | \mathbf{Y}_{1,1:n}, \mathbf{Y}_{2,1:n})$ 、

$p(\boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{\Lambda,i}^R | \mathbf{Y}_{1,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 和 $p(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_{\eta,i}^R | \mathbf{Y}_{2,1:n}, \mathbf{X}^E, \mathbf{X}^O)$ 中抽取的模型参数后验分布的样本 $(\hat{\boldsymbol{\theta}}_{IG}^F, \hat{\boldsymbol{\theta}}_{\Lambda,i}^R, \hat{\boldsymbol{\theta}}_W^F, \hat{\boldsymbol{\theta}}_{\eta,i}^R, \hat{\boldsymbol{\theta}}_C)$ ，并在此基础上计算式(5-33)中的 $C(u_{i,q_i}, v_{i,q_i} | \hat{\boldsymbol{\theta}}_C)$ 以及式(5-34)中的 $F^{-1}(u_{i,q_i} | x_{i,q_i}^E, x_{i,q_i}^O, \boldsymbol{\theta}_{IG}^F, \boldsymbol{\theta}_{\Lambda,i}^R)$ 和 $F^{-1}(v_{i,q_i} | x_{i,q_i}^E, x_{i,q_i}^O, \boldsymbol{\theta}_W^F, \boldsymbol{\theta}_{\eta,i}^R)$ ；与此同时，通过 Copula 函数中的样本 u_{i,q_i} 和 v_{i,q_i} 将所有的计算联系起来，从而完成由式(5-33)至(5-34)的计算实现。

(3) 机床可靠性和剩余寿命的评估

由于式(5-19)和(5-20)所示的机床可靠性和剩余寿命都不存在解析的表达式，在进行机床可靠性和剩余寿命评估时需要按照式(5-19)和(5-20)给出的定义方式来进行数值计算。机床的可靠性和剩余寿命都是定义在机床故障时间变量 T 上的函数，而该时间变量 T 的计算则需要通过机床的多性能退化过程与各自对应的性能退化阈值之间的关系来确定。因此，机床可靠性和剩余寿命的评估可以通过对未来一系列观测时间点上的性能退化进行预测，并对比预测的性能退化值与各自的性能退化阈值来获得故障时间 T ，从而进一步对机床的可靠性和剩余寿命进行评估。根据式(5-19)和(5-20)给出的机床可靠性和剩余寿命的定义以及式(5-34)中给出的未来观测点性能退化预测的方式，可以得到机床可靠性和剩余寿命评估的计算表达式：

$$\begin{aligned} R(t_{i,q_i}) &= \Pr(y_1(t_{i,q_i}) \leq D_1, y_2(t_{i,q_i}) \leq D_2), \\ T_i^{\text{RUL}} &= \inf \{ L : y_1(t_{i,m_i} + L) > D_1 \text{ or } y_2(t_{i,m_i} + L) > D_2 \}, \\ y_1(t_{i,q_i}) &= y_1(t_{i,q_i-1}) + \Delta y_1(t_{i,q_i}), y_2(t_{i,q_i}) = y_2(t_{i,q_i-1}) + \Delta y_2(t_{i,q_i}), \\ L &= t_{i,q_i} - t_{i,m_i}, q_i = m_i + 1, \dots, M_i \rightarrow +\infty \end{aligned} \quad (5-35)$$

式中， $t_{i,q_i}, q_i = m_i + 1, \dots, M_i \rightarrow +\infty$ 为性能退化数据 $\{\mathbf{Y}_{1:n}, \mathbf{X}^E, \mathbf{X}^O\}$ 最近观测时间点 t_{i,m_i} 之后的一系列未来观测点序列。

式(5-35)所描述的机床可靠性与剩余寿命的评估是建立在对未来观测时间点序列的性能退化预测的基础上的，该式的计算实现算法如图 5-5 所示。该算法的核心在于利用参数后验分布样本 $(\hat{\boldsymbol{\theta}}_{IG}^F, \hat{\boldsymbol{\theta}}_{\Lambda,i}^R, \hat{\boldsymbol{\theta}}_W^F, \hat{\boldsymbol{\theta}}_{\eta,i}^R, \hat{\boldsymbol{\theta}}_C)^{(g)}$ ($g = 1, \dots, G$)，并在此基础上依次获得时间序列 $t_{i,q_i}, q_i = m_i + 1, \dots, M_i \rightarrow +\infty$ 上的性能退化预测值直到某一观测时间点的性能退化预测值存在 $y_1(t_{i,q_i}) > D_1$ 或 $y_2(t_{i,q_i}) > D_2$ ，即获得机床发生故障的首次穿越时间 $T_i^{(g)}$ 。 $T_i^{(g)}$ 即为机床寿命分布的样本，通过其进行统计并结合机床当前观测时间点 t_{i,m_i} ($i = 1, \dots, n$) 即可获得每一台机床样本的可靠性和剩余寿命的评估结果。

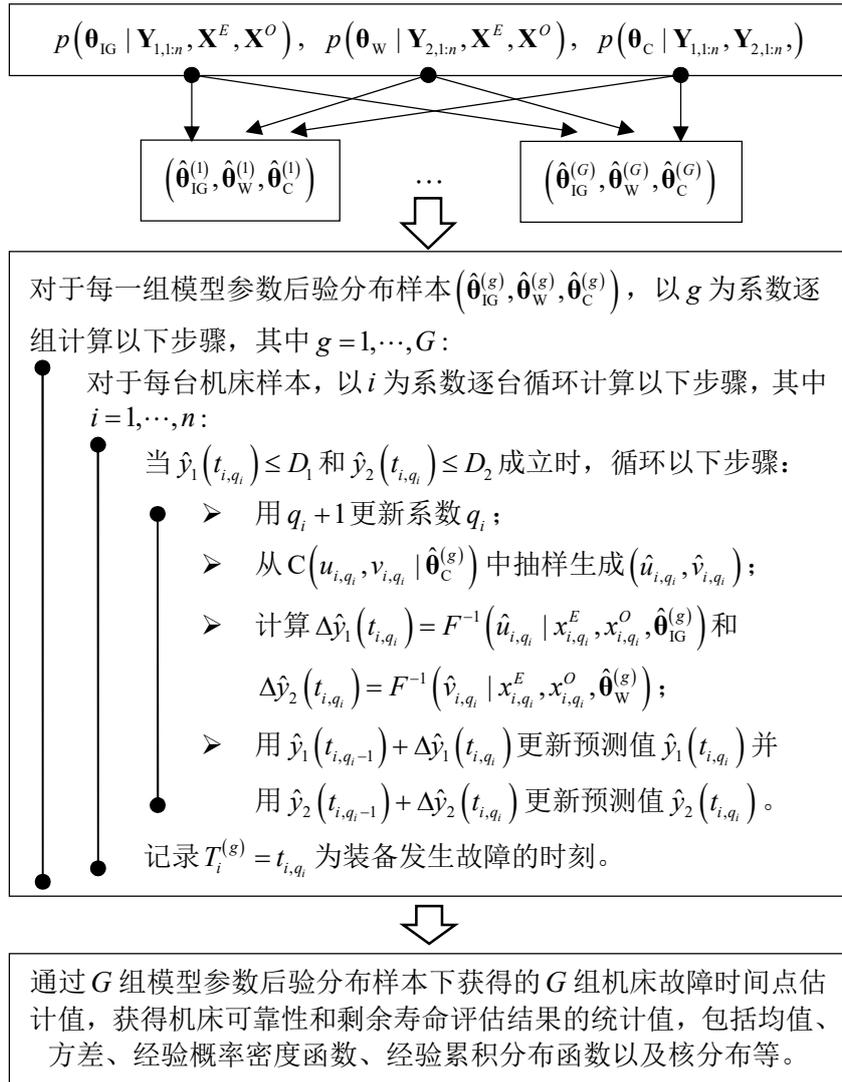


图 5-5 基于数值积分的机床可靠性评估与剩余寿命预测实现算法

5.5 算例分析

某型超重型卧式镗车床（重型卧车）是某重型机械集团锻造厂金工车间当家把关的重型数控机床，主要承担着核电关键设备、超重型轧辊、巨型船舶舵轴和驱动轴、超大功率汽轮机转子、水轮发电机主轴及大电机主轴等的加工任务，这些零部件均为国防战略装备急需而又无法从国外进口的超大超重型零部件。为了保证该超重型卧式镗车床高的可靠性和可用性，在国家科技重大专项“高档数控机床与基础制造装备”的支撑下对该型重型卧车的可靠性建模、分析和评估技术进行了研究。

该型重型卧车的关键子系统主要包括主轴子系统和液压子系统。为了在服役阶段保持该重型卧车高的可靠性、可用性和生产效率，同时降低使用、维护和维

修等产生的总体拥有成本，对主轴子系统和液压子系统的性能指标以及重型卧车所处的工作环境和所经历的加工任务进行状态监控，并在此基础上对重型卧车的可靠性进行建模与评估。本章以该重型卧车的状态监测数据分析与机床可靠性评估为例来对基于状态监测数据的可靠性建模与评估技术进行示例性说明。

出于方法示例性说明以及对主机厂和用户厂信息的保护，本文所采用的数据是对原有数据进行适当处理之后，保留动态环境与任务下多性能退化数据的特性而剔除相关指标参数细节的数据，这样可以将重点集中在多性能退化数据分析、建模以及基于数据分析的可靠性评估上。

5.5.1 状态监测数据

本章所采用的状态监测数据为 5 台重型卧车在 10 个任务区间内的状态监测数据，分别如图 5-6 和图 5-7 所示。令 $Y_1(t)$ 描述液压子系统对应指标的性能退化过程， $Y_2(t)$ 描述主轴系统对应指标的性能退化过程， X^E 为工作环境变量， X^O 为加工任务变量。

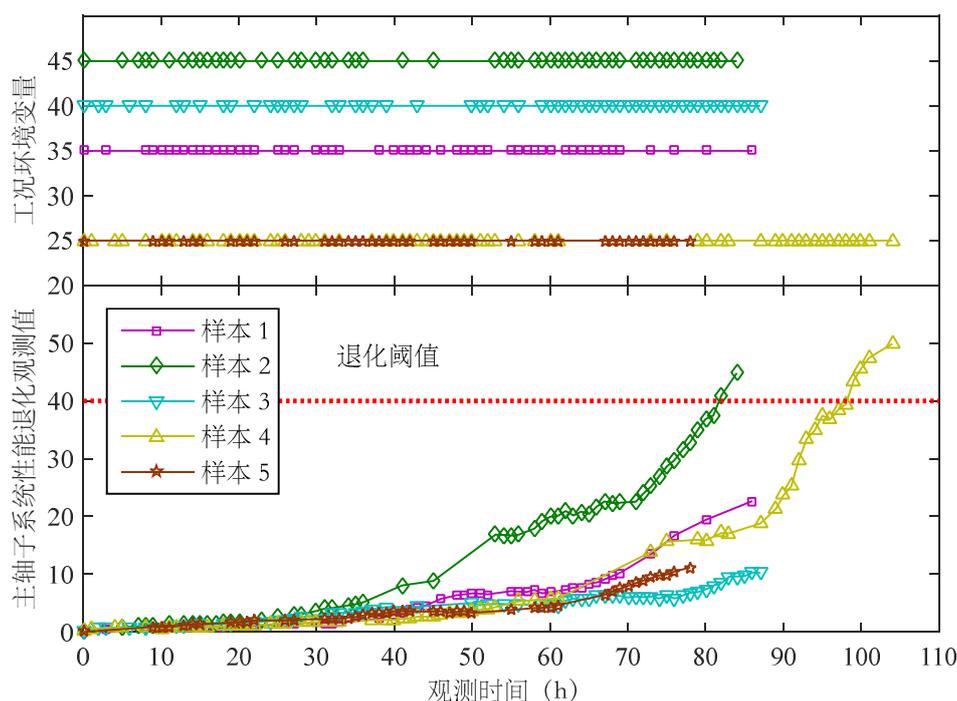


图 5-6 液压子系统性能退化和工作任务观测数据

该状态监测数据为完整的状态监测数据，可将性能退化观测数据统一描述为： $y_k(t_{ihj})$ ($k=1,2,i=1,\dots,5,h=1,\dots,10,j=1,\dots,m_{ih}$)，其中 k 为液压子系统 ($k=1$) 和主轴子系统 ($k=2$) 的系数， i 为重型车床样本的系数， h 为工作任务的系数，

j 为观测点的系数。 $y_k(t_{ihj})$ 即为第*i*个重型车床样本的第*k*个子系统,在第*h*个任务区间内的第*j*个观测时间点观测到的性能退化值(每个任务区间内的总的观测点数为 m_{ih} 个)。 x_i^o 为第*i*个重型车床样本所处工作环境变量的观测值; x_{ih}^E 为第*i*个重型车床样本在第*h*个任务区间内所经历工作任务变量的观测值。此外,对于液压子系统和主轴子系统性能退化过程的性能退化阈值分别为 $D_1 = 80$ 和 $D_2 = 40$ 。

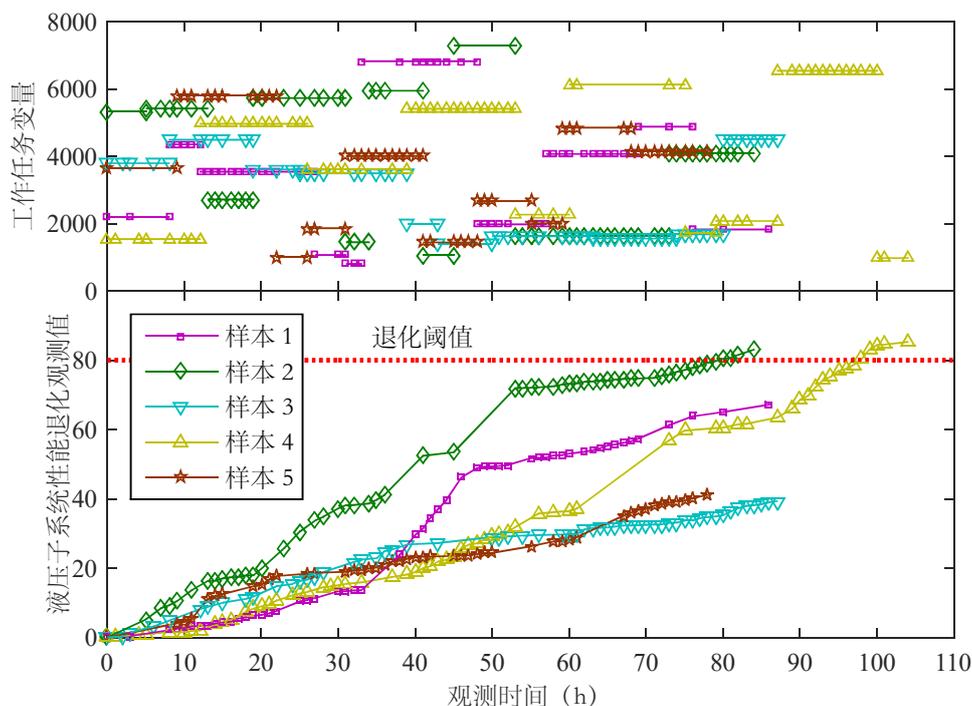


图 5-7 主轴子系统性能退化和工作环境观测数据

5.5.2 状态监测数据的建模与模型参数估计

在获得图 5-6 和图 5-7 所示的性能退化数据之后,首先对 $Y_1(t)$ 和 $Y_2(t)$ 之间可能存在的相关关系进行定性分析。本文采用散点图的形式分别将 $Y_1(t)$ 和 $Y_2(t)$ 的退化增量以及 $Y_1(t)$ 和 $\log(Y_2(t))$ 的退化增量绘制出来,如图 5-8 所示。从散点图可知: $Y_1(t)$ 的退化增量和 $\log(Y_2(t))$ 的退化增量之间存在较强的相关关系,且分别记 $\Delta y_1(t_{ihj}) = y_1(t_{ihj}) - y_1(t_{ih,j-1})$ 和 $\Delta \log(y_2(t_{ihj})) = \log(y_2(t_{ihj})) - \log(y_2(t_{ih,j-1}))$ 为 $Y_1(t)$ 和 $\log(Y_2(t))$ 的退化增量。因此,可以确认性能退化过程 $Y_1(t)$ 和 $Y_2(t)$ 之间存在相关关系,且可以采用 5.3 节所建立的多性能退化过程模型来对其进行建模分析。

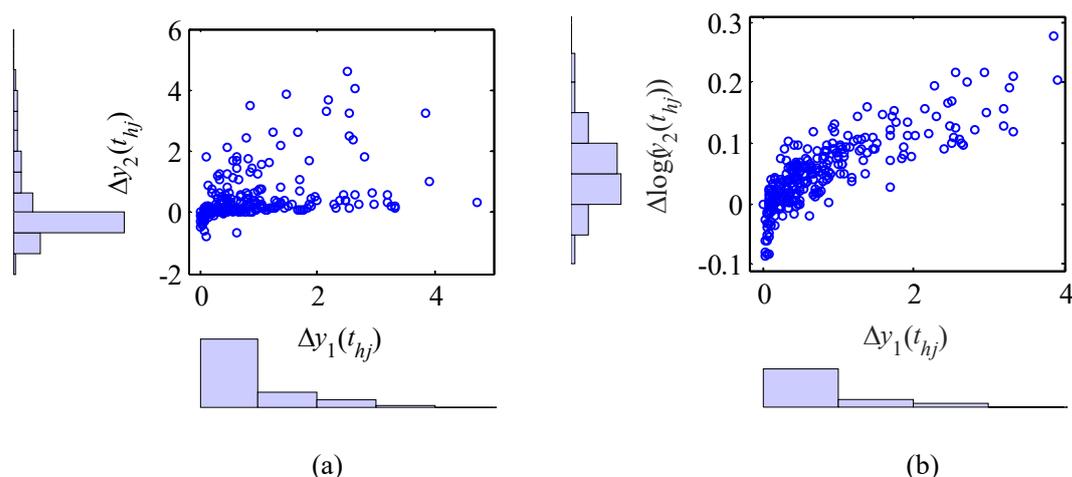


图 5-8 主轴子系统和液压子系统对应性能退化增量的散点图

(a) $Y_1(t)$ 和 $Y_2(t)$ 的退化增量的散点图；(b) $Y_1(t)$ 和 $\log(Y_2(t))$ 的退化增量的散点图

本文采用 5.3.3 节所建立的多性能退化模型来对该状态监测数据进行建模分析。结合图 5-6 和图 5-7 中各性能退化过程的轨迹特性，对于液压子系统的性能退化过程 $Y_1(t)$ 采用线性均值函数的逆高斯过程模型来建模，对于主轴子系统的性能退化过程 $Y_2(t)$ 采用 Gebraeel 等^[171]提出的指数型退化过程模型来建模。

$$\begin{aligned}
 y_1(t_{ihj}) &\sim \text{IG}(\beta_1 t_{ihj}, \lambda_1 (\beta_1 t_{ihj})^2), i=1, \dots, 5; h=1, \dots, 10, \\
 \log(y_2(t_{ihj})) &\sim \text{N}(\theta_2 + \beta_2 t_{ihj}, \sigma_2^2 t_{ihj}), j=1, \dots, m_{ih}
 \end{aligned}
 \tag{5-36}$$

与此同时，将工作环境变量 x_i^E 和工作任务变量 x_{ih}^O 采用 5.3.3 节中所描述的方法引入到边缘退化过程模型中去。本章中对于工作环境变量首先进行了对数化处理，即将 $\log(x_i^E)$ 引入到模型中去；对于工作任务变量 x_{ih}^O 进行了偏移量比例化处理，即将 $(x_{ih}^O - x_0^O)/x_0^O$ 引入到模型中去，其中 x_0^O 为工作任务变量的典型特征值；这些预处理的目的是为了调整这些变量的取值以使其适应模型中整体参数和变量的取值，增强模型的稳健性。本文中变量 x_i^E 和 x_{ih}^O 引入方式的确定是结合了变量对退化机理的影响以及对比了不同形式下的分析结果再最终确定的。对于变量 x_i^E 的引入在逆高斯过程模型和维纳过程模型中都是采用式(5-11)所示的线性方式，对于变量 x_{ih}^O 的引入在逆高斯过程模型中采用式(5-13)所示的指数方式而在维纳过程模型中则是采用式(5-11)所示的线性方式。进一步考虑不同重型车床样本对于不同的工作环境往往存在个体差异性，在变量 x_i^E 引入的模型中构建随机影响模型。综合以上建模的考虑，构建重型卧车状态监测数据的模型如下：

$$\begin{aligned}
 \Delta y_1(t_{ihj}) &\sim \text{IG}\left(\Delta\Lambda_1(t_{ihj}), \lambda_1 \Delta\Lambda_1(t_{ihj})^2\right), i=1, \dots, 5; h=1, \dots, 10, \\
 \Delta \log(y_2(t_{ihj})) &\sim \text{N}\left(\mu_{2ih} \Delta t_{ihj}, \sigma_2^2 \Delta t_{ihj}\right), j=1, \dots, m_{ih}, \\
 F\left(\Delta y_1(t_{ihj}), \Delta \log(y_2(t_{ihj}))\right) &= C\left(F\left(\Delta y_1(t_{ihj})\right), F\left(\Delta \log(y_2(t_{ihj}))\right) \mid \boldsymbol{\theta}_C\right), \\
 \Delta\Lambda_1(t_{ihj}) &= \left(\beta_1 + \beta_{1i}^E \log(x_i^E)\right) \exp\left(\beta_1^O \frac{x_{ih}^O - x_0^O}{x_0^O}\right) \Delta t_{ihj}, \beta_{1i}^E \sim \text{Gamma}(\delta_1, \gamma_1), \\
 \mu_{2ih} &= \beta_2 + \left(\beta_{2i}^E \log(x_i^E) + \beta_2^O \frac{x_{ih}^O - x_0^O}{x_0^O}\right), \beta_{2i}^E \sim \text{Gamma}(\delta_2, \gamma_2)
 \end{aligned} \tag{5-37}$$

式中, $\Delta t_{ihj} = t_{ihj} - t_{ih,j-1}$, 逆高斯过程模型的退化增量为 $\Delta y_1(t_{ihj})$, 对应模型参数包括固定参数 $\boldsymbol{\theta}_{\text{IG}}^F = \{\beta_1, \beta_{1i}^O, \lambda_1\}$ 、随机参数 $\boldsymbol{\theta}_{\Lambda,i}^R = \{\beta_{1i}^E\}$ 和超参数 $\boldsymbol{\theta}_{\text{IG}}^H = \{\delta_1, \gamma_1\}$; 维纳过程模型的退化增量为 $\Delta \log(y_2(t_{ihj}))$, 对应参数包括固定参数 $\boldsymbol{\theta}_W^F = \{\theta_2, \beta_2, \beta_2^O, \sigma_2\}$ 、随机参数 $\boldsymbol{\theta}_{\eta,i}^R = \{\beta_{2i}^E\}$ 和超参数 $\boldsymbol{\theta}_W^H = \{\delta_2, \gamma_2\}$ 。

式(5-37)所建立的模型中并没有给定 Copula 函数的具体形式, 这是因为目前还没有获得性能退化过程 $Y_1(t)$ 和 $Y_2(t)$ 相关关系的具体信息。根据 5.4 中所构建的基于贝叶斯方法的多性能退化分析方法, 可以首先应用该方法对式(5-37)中边缘性能退化过程模型的参数进行估计。根据式(5-23)和式(5-24)可以得到状态监测数据分析 and 边缘退化过程模型参数估计的数学表达式为:

$$\begin{aligned}
 p\left(\boldsymbol{\theta}_{\text{IG}}^F, \boldsymbol{\theta}_{\text{IG}}^R, \boldsymbol{\theta}_{\text{IG}}^H \mid \mathbf{Y}_{1,1:5}, \mathbf{X}^E, \mathbf{X}^O\right) &\propto \pi\left(\beta_1, \beta_{1i}^O, \delta_1, \gamma_1, \lambda_1\right) \times \\
 \prod_{i=1}^5 \frac{\gamma_1^{\delta_1} \left(\beta_{1i}^E\right)^{\delta_1-1} e^{-\gamma_1 \beta_{1i}^E}}{\int_0^\infty x^{\delta_1-1} e^{-x} dx} &\prod_{i=1}^8 \prod_{j=2}^{m_{ih}} \sqrt{\lambda_1} \Delta\Lambda_1(t_{ihj}) \exp\left(-\frac{\lambda_1 \left(\Delta y_1(t_{ihj}) - \Delta\Lambda_1(t_{ihj})\right)^2}{2\Delta y_1(t_{ihj})}\right) \\
 p\left(\boldsymbol{\theta}_W^F, \boldsymbol{\theta}_W^R, \boldsymbol{\theta}_W^H \mid \mathbf{Y}_{2,1:5}, \mathbf{X}^E, \mathbf{X}^O\right) &\propto \pi\left(\theta_2, \beta_2, \beta_2^O, \delta_2, \gamma_2, \sigma_2\right) \times \\
 \left[\frac{\gamma_2^{\delta_2} \left(\beta_{2i}^E\right)^{\delta_2-1} e^{-\gamma_2 \beta_{2i}^E}}{\int_0^\infty x^{\delta_2-1} e^{-x} dx} \phi\left(\frac{\log(y_2(t_{i,1,2})) - \mu_{2ih} t_{i,1,2}}{\sigma_2 \sqrt{t_{i,1,2}}}\right) \right] &\times \\
 \prod_{i=1}^5 \prod_{j=3}^{m_{i1}} \phi\left(\frac{\Delta \log(y_2(t_{i1j})) - \mu_{2i1}(t_{i1j} - t_{i1,j-1})}{\sigma_2 \sqrt{t_{i1j} - t_{i1,j-1}}}\right) &\times \\
 \prod_{h=2}^8 \prod_{j=2}^{m_{ih}} \phi\left(\frac{\Delta \log(y_2(t_{ihj})) - \mu_{2ih}(t_{ihj} - t_{ih,j-1})}{\sigma_2 \sqrt{t_{ihj} - t_{ih,j-1}}}\right) &
 \end{aligned} \tag{5-39}$$

式中, $\boldsymbol{\theta}_{\text{IG}}^R = \{\beta_{1,1}^E, \dots, \beta_{1,5}^E\}$, $\boldsymbol{\theta}_W^R = \{\beta_{2,1}^E, \dots, \beta_{2,5}^E\}$, $\mathbf{Y}_{1,1:5}, \mathbf{Y}_{2,1:5}, \mathbf{X}^E, \mathbf{X}^O$ 分别为 $Y_1(t)$ 、 $Y_2(t)$ 、工作环境和工作任务的观测数据; $\pi(\cdot)$ 为模型参数的先验分布, 本文中采用均匀分布形式的无信息先验分布, 使得模型参数的估计完全依赖于观测数据; $p(\cdot)$ 为模型参数的后验分布。

通过 OpenBUGS 软件对模型参数的后验分布进行 MCMC 抽样，并对后验样本进行统计分析，获得模型参数的估计结果如表 5-1 所示。

表 5-1 边缘退化过程模型参数的估计结果

模型参数	统计特征值		后验置信区间		模型先验分布
	均值	方差	2.5%	97.5%	
β_1	0.1759	0.01609	0.1464	0.2098	Uniform(0,10)
λ_1	2.199	0.3122	1.628	2.853	Uniform(0,10)
β_1^o	0.4247	0.02019	0.385	0.4645	Uniform(0,10)
δ_1	-73.42	19.31	-98.69	-31.51	Uniform(-100,100)
γ_1	34.06	24.45	1.601	90.2	Uniform(0,100)
θ_2	-0.5394	0.02138	-0.581	-0.4974	Uniform(-10,10)
β_2	0.008443	0.002704	0.003204	0.01383	Uniform(0,10)
σ_2	0.04571	0.002319	0.04146	0.05057	Uniform(0,10)
β_2^o	0.01249	0.0007	0.01104	0.01393	Uniform(0,10)
δ_2	-71.77	22.92	-99.12	-25.5	Uniform(-100,100)
γ_2	20.73	19.15	0.7573	74.5	Uniform(0,100)

根据图 5-3 所示的框架，当获得边缘退化过程模型参数的估计结果时，可得到退化增量 $\Delta y_1(t_{ihj})$ 和 $\Delta \log(y_2(t_{ihj}))$ 在各自边缘退化过程对应分布模型下的累积概率分布函数值 $(F(\Delta y_1(t_{ihj})), F(\Delta \log(y_2(t_{ihj}))))$ 。这些累积概率分布函数的取值即为 Copula 函数参数评估的输入信息，其散点图如图 5-9 所示。从图中可知两个退化过程退化增量对应的累积概率分布函数的取值之间存在着“纺锤形”的散点相关关系，可以采用高斯 Copula 函数来对这种类型的相关关系进行建模：

$$\begin{aligned}
 F(\Delta y_1(t_{ihj}), \Delta \log(y_2(t_{ihj}))) &= C(F(\Delta y_1(t_{ihj})), F(\Delta \log(y_2(t_{ihj}))) | \theta_C) \\
 &= \int_{-\infty}^{\Phi^{-1}(u_{ihj})} \int_{-\infty}^{\Phi^{-1}(v_{ihj})} \frac{1}{2\pi\sqrt{1-\alpha^2}} \exp\left\{-\frac{x^2 - 2\alpha xy - y^2}{2(1-\alpha^2)}\right\} dx dy, \quad (5-40) \\
 u_{ihj} &= F(\Delta y_1(t_{ihj})), v_{ihj} = F(\Delta \log(y_2(t_{ihj})))
 \end{aligned}$$

式中， $\theta_C = \{\alpha\}$ 且 $-1 \leq \alpha \leq 1$ ， $\Phi^{-1}(\bullet)$ 为标准正态分布累积概率分布函数的逆函数。

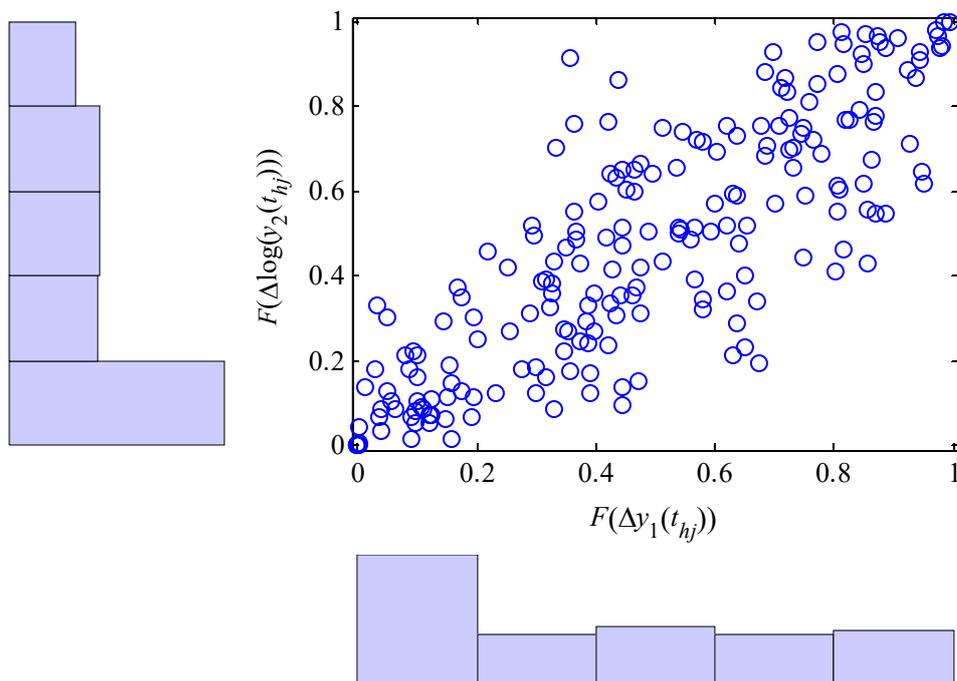


图 5-9 边缘退化增量对应累积概率分布函数取值的散点图

根据图 5-9 所示的边缘退化增量对应累积概率分布函数取值，结合式(5-29)可以构建高斯 Copula 函数参数估计的表达式：

$$\begin{aligned}
 p(\alpha | \mathbf{Y}_{1,1:5}, \mathbf{Y}_{2,1:5}, \mathbf{X}^E, \mathbf{X}^O) &\propto \pi(\alpha) \times \\
 \prod_{i=1}^5 \prod_{h=1}^8 \prod_{j=2}^{m_{ih}} \frac{1}{\sqrt{1-\alpha^2}} \exp \left\{ -\frac{(a_{ihj})^2 - 2a_{ihj}b_{ihj}\alpha - (b_{ihj})^2}{2(1-\alpha^2)} \right\}, & \quad (5-41) \\
 a_{ihj} &= \Phi^{-1} \left(F \left(\Delta y_1(t_{ihj}) | x_i^E, x_{ih}^O, \hat{\boldsymbol{\theta}}_{IG}^F, \hat{\boldsymbol{\theta}}_{\Lambda,i}^R \right) \right), \\
 b_{ihj} &= \Phi^{-1} \left(F \left(\Delta \log(y_2(t_{ihj})) | x_i^E, x_{ih}^O, \hat{\boldsymbol{\theta}}_W^F, \hat{\boldsymbol{\theta}}_{\eta,i}^R \right) \right)
 \end{aligned}$$

式中， $\pi(\alpha)$ 为 α 的先验分布，本章选用 $[-1,1]$ 区间上的均匀分布来表示无先验信息输入； $F(\Delta y_1(t_{ihj}) | x_i^E, x_{ih}^O, \hat{\boldsymbol{\theta}}_{IG}^F, \hat{\boldsymbol{\theta}}_{\Lambda,i}^R)$ 和 $F(\Delta \log(y_2(t_{ihj})) | x_i^E, x_{ih}^O, \hat{\boldsymbol{\theta}}_W^F, \hat{\boldsymbol{\theta}}_{\eta,i}^R)$ 可将式(5-37)中的相应部分代入式(5-26)和(5-27)来得到。

通过 OpenBUGS 软件对模型参数的后验分布进行 MCMC 抽样，并对后验样本进行统计分析，获得模型参数的估计结果如表 5-2 所示。从参数 α 的评估结果可以看出，性能退化过程 $Y_1(t)$ 和 $Y_2(t)$ 之间存在较大的相关性，这也与图 5-8 和图 5-9 中所表现出来的相关性对应。

至此，已经完成了对图 5-6 和图 5-7 所示的状态监测数据进行建模，并对模型

参数进行了估计，得到了模型参数的后验分布、后验分布的样本以及参数的点估计和区间估计值。

表 5-2 高斯 Copula 函数模型参数的估计结果

模型参数	统计特征值		后验置信区间	
	均值	方差	2.5%	97.5%
α	0.9417	0.0060	0.9289	0.9523

5.5.3 模型验证、对比与重型卧车剩余寿命评估

本节将采用交叉验证和模型对比的方法对模型进行验证，并在模型验证的基础上利用该模型对重型卧车的剩余寿命进行评估。

在上文模型参数的估计中只用到了 5 台重型卧车样本前 8 个任务时间的状态监测数据，剩余的 2 个任务时间的状态监测数据作为交叉验证点来对模型进行交叉验证。通过对比模型在这 2 个任务时间内相应观测时间上的退化预测值与实际观测值之间的差距，对模型的建模能力与预测能力进行判断。根据 5.4.3 节中所描述的未来观测点的性能退化预测方法，基于模型参数的后验样本对交叉验证点的性能退化值进行预测，预测值与观测值的对比如图 5-10 所示。

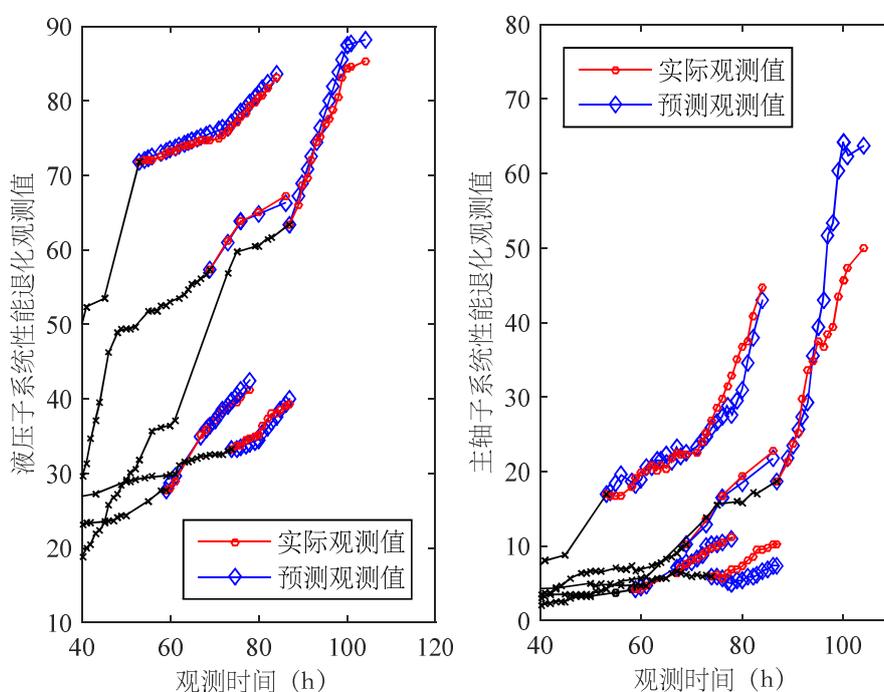


图 5-10 交叉验证点的性能退化预测值与观测值对比

从图中可以看出，模型的预测结果与实际观测值较为接近，这说明了模型能够对重型卧车的状态监测数据进行较好的描述并且具有较好的性能退化预测能力。为了进一步验证模型性能退化预测的能力，图 5-11 描述了在交叉验证点中最后一个观测点的预测值与观测值之间的相对误差。从图中可以得出对于最后一个观测点的预测值与观测值之间的相对误差较小，多数处于可以接受的预测误差范围之内（±5%）。

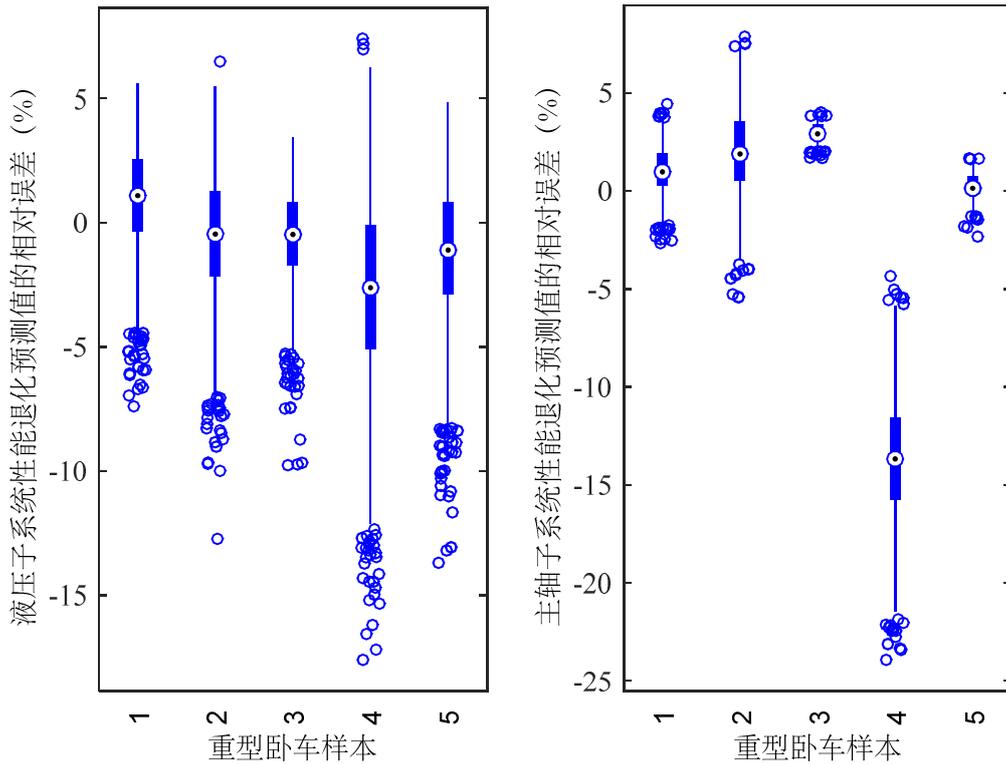


图 5-11 最后一个观测点的预测值与观测值之间的相对误差

为了进一步对比本文所建立的模型和常规的不考虑环境与任务变量模型的预测能力，本文采用同样的基础边缘退化过程模型和 Copula 函数模型构建了不考虑环境与任务变量的多性能退化模型如下：

$$\begin{aligned}
 \Delta y_1(t_{ihj}) &\sim \text{IG}(\beta_1 \Delta t_{ihj}, \lambda_1 (\beta_1 \Delta t_{ihj})^2), i = 1, \dots, 5, h = 1, \dots, 10, \\
 \Delta \log(y_2(t_{ihj})) &\sim \text{N}(\beta_2 \Delta t_{ihj}, \sigma_2^2 \Delta t_{ihj}), j = 1, \dots, m_{ih} \\
 F(\Delta y_1(t_{ihj}), \Delta \log(y_2(t_{ihj}))) &= C(F(\Delta y_1(t_{ihj})), F(\Delta \log(y_2(t_{ihj})))) | \theta^C
 \end{aligned}
 \tag{5-42}$$

通过采用同样的基于贝叶斯方法的多性能退化分析方法，应用式(5-42)所示的多性能退化模型来对重型卧车的状态监测数据进行分析，并对交叉验证点的性能

退化进行预测。在此基础上，可以得到本文所建立的多性能退化过程模型和不考虑环境与任务变量的多性能退化模型下，交叉验证点的性能退化预测值与实际观测值之间的对比，如图 5-12 所示。从图中可知，本文所建立模型的预测结果比不考虑环境与任务变量的多性能退化模型的预测结果更接近实际观测值，这说明本文所建立的模型在性能退化预测方面具有更好的优势，这也从另一侧面说明了环境与任务变量对性能退化的影响不可忽略。

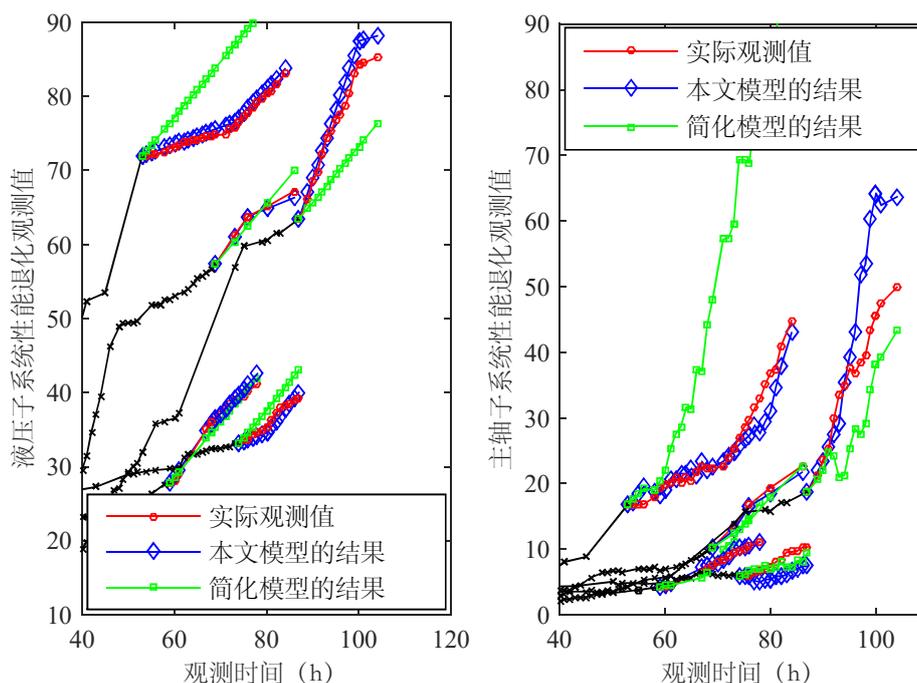


图 5-12 本文模型和简化模型在交叉验证点的性能退化预测值与观测值对比

在此基础上，进一步应用 5.4.3 节中所给出的剩余寿命评估的方法，分别在本文所建立的模型和不考虑环境与任务变量的模型下进行剩余寿命的评估。由于第 2 台和第 4 台重型卧车样本在最后的两个任务区间内的性能退化都超出了给定的性能退化阈值，即当采用前 8 个区间的性能退化数据进行模型参数估计和剩余寿命评估时，这两个样本的剩余寿命的实际观测值是已知的。与性能退化的交叉验证类似，可以对比第 2 台和第 4 台重型卧车的剩余寿命评估值与实际观测值来判断本文所提出模型和方法的好坏。

根据 5.4.3 节中所描述的剩余寿命评估方法，基于对所有重型卧车样本前 8 个工作任务区间的性能退化分析所得的模型参数后验样本，对第 2 台和第 4 台重型卧车样本的剩余寿命进行评估，其结果如图 5-13 所示。从评估结果可知，本文所提出模型和方法的评估值结果与实际观测值一致，且将评估结果的不确定性也考

虑了进去；而简化模型（不考虑环境与工作应力变量模型）的结果却与实际观测值间存在较大的偏差。这说明了本文所提出的模型和方法能对重型卧车的剩余寿命进行较好的评估。

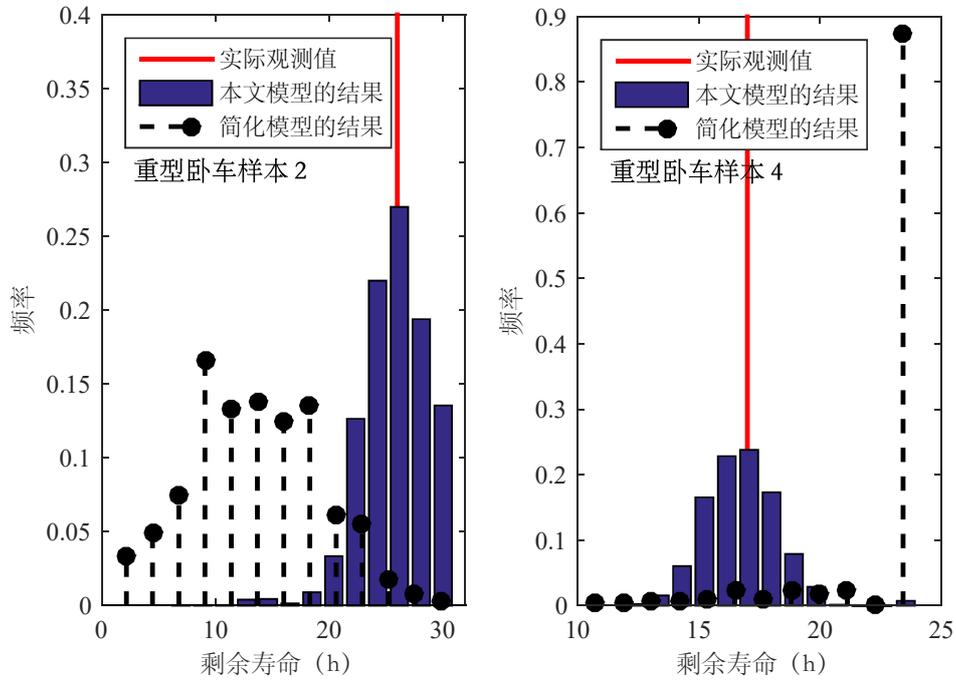


图 5-13 本文模型和简化模型剩余寿命估计值与实际值对比

综合以上的交叉验证和模型对比可知：本文所建立考虑动态环境和任务的多性能退化过程模型能够对重型卧车的状态监测数据进行较好的建模描述，同时基于贝叶斯方法的多性能退化分析方法能够对重型卧车的状态监测数据进行较好的分析，并且具有较好的性能退化预测与剩余寿命评估的能力。

5.6 本章小结

本文针对重型数控机床状态监测数据分析中多性能退化和动态环境和任务影响的关键问题，结合不完全状态监测数据下机床性能退化预测、剩余寿命评估以及结果不确定性表征的实际需求，研究了重型数控机床基于状态监测数据的可靠性建模与评估技术。首先，提出了动态环境下多性能退化建模的基本框架，并构建了基于 Copula 的多性能退化模型，实现了对具有多种退化轨迹形式的多性能退化过程的建模描述。然后，利用多性能退化过程模型中退化均值函数的物理特性，并按照加速性能退化建模的基本思路，通过协变量的方式将动态环境与任务变量引入到多性能退化模型中，实现了考虑动态环境与任务的多性能退化建模。在此

基础上，通过整合基于贝叶斯方法的性能退化分析与基于 Copula 函数的多性能退化建模两者的优势，构建了基于贝叶斯方法的多性能退化分析的基本框架，重点研究了不完全状态监测数据下多性能退化模型参数的估计、缺失观测点和未来观测点性能退化的预测以及剩余寿命评估的方法。最后，通过算例分析对模型和方法进行了应用示例和验证，结果表明本文方法比传统方法具有更好的建模能力和更高的评估精度。

第六章 全文总结与展望

6.1 全文总结

重型数控机床作为高精尖的国家战略性“工作母机”，肩负着航空航天、发电设备、大型船舶、轨道交通和海洋工程等行业关键产品和零部件的加工制造；其技术水平的高低和可靠性的好坏已成为影响我国经济安全、产业安全甚至国防安全的关键所在。重型数控机床虽然经历了产品型号“从无到有”的突破以及性能指标“从劣到优”的提升，但是其可靠性水平和相应技术的发展却严重滞后，甚至逐渐成为制约重型数控机床发展的关键所在。

可靠性建模与评估技术是重型数控机床的关键基础共性技术：正确的可靠性建模是开展可靠性设计、可靠性试验和可靠性增长的前提，而精确的可靠性评估则是对数控机床进行定量控制、研制考核和健康管理的保障。针对重型数控机床的特性，研究重型数控机床的可靠性建模与评估技术具有重要的学术价值和实际工程意义。本文针对重型数控机床可靠性建模与评估中诸多亟待解决的关键问题，开展了探索性研究，主要成果概述如下：

（1）基于故障时间数据的重型数控机床可靠性建模与评估

系统地研究了完好维修、最小维修和非完好维修下故障时间数据的建模方法。提出了故障关联因子模型，形成了同时计及维修程度和故障关联程度的故障时间数据建模方法，弥补了现有故障时间数据模型的缺陷。在此基础上，提出了基于贝叶斯模型综合方法的故障时间数据分析和系统可靠性评估方法，其中涵盖了基于贝叶斯方法的完好维修、最小维修和非完好维修下考虑故障关联程度的故障时间数据分析方法，也包含了基于故障时间数据分析的模型不确定性量化与多模型选择的方法。这些方法解决了重型数控机床故障时间数据分析中多种维修情形下多数据模型混合的建模评估问题。

（2）基于多源层次信息集的重型数控机床可靠性建模与评估

提出了针对重型数控机床的多源层次信息集的建模方法，其中包含了系统层次结构的可靠性建模方法以及层次多类型数据的可靠性建模方法，该建模方法为多源层次客观数据的建模融合提供了模型基础。提出了混合贝叶斯方法与贝叶斯网络的多源层次信息融合评估方法，其中包含了基于贝叶斯方法的独立来源层次客观数据的融合方法、基于贝叶斯网络的层次覆盖客观数据的融合方法以及基于贝叶斯网络的层次主客观信息的融合方法。这些方法拓展了现有多源层次信息融合建模评估的方法体系，解决了重型数控机床多源层次信息融合评估中数据的多

样性、覆盖性以及信息的主客观共存性所带来的建模和评估的难题。

(3) 基于性能检测数据的重型数控机床可靠性建模与评估

系统地研究了基于维纳过程、伽玛过程和逆高斯过程的性能检测数据建模方法，在此基础上提出了性能演变速率模型并将其与随机效应模型同时引入到逆高斯过程模型中构建了多个改进的逆高斯过程模型，解决了重型数控机床性能演变过程建模中轨迹多样性、个体差异性和性能波动性等建模难题。构建了基于贝叶斯方法的性能检测数据分析与可靠性评估方法，其中包含了基于 MCMC 的模型参数估计、考虑个体差异性的性能演变过程预测与剩余寿命评估的方法，也包含了应对性能检测数据动态更新的贝叶斯融合评估方法。这些方法解决了融合主机厂和用户厂性能检测数据的可靠性协同评估的问题。

(4) 基于状态监测数据的重型数控机床可靠性建模与评估

提出了基于 Copula 函数和多种随机过程的多性能退化建模方法，在此基础上利用随机过程均值函数的物理特性以及协变量和随机影响模型的建模能力，将工作环境变量和工作任务变量引入到多性能退化模型中，构建了考虑动态环境与任务应力的多性能退化模型，解决了机床状态监测数据建模中多性能退化和动态环境与任务应力影响的关键问题。提出了基于贝叶斯方法的多性能退化分析方法，其中包涵了多退化过程模型参数的两步估计方法、缺失观测点和未来观测点的性能退化预测方法以及考虑个体差异性的剩余寿命评估方法。这些方法满足了重型数控机床在不完全状态监测数据下机床性能退化预测、剩余寿命评估以及结果不确定性表征的实际需求。

本文所构建的四种重型数控机床可靠性建模与评估的方法，从整体上覆盖了寿命周期不同阶段所对应的不同可靠性信息类型，四种方法各有优势和落脚点。基于故障时间数据的可靠性建模与评估方法主要适用于整机级的故障时间数据的建模分析，此时如果没有子系统和零部件的可靠性数据或者没有系统的性能检测和状态监测数据，则无法采用后续的三种可靠性建模与评估方法。基于多源层次信息集的可靠性建模与评估方法主要适用于整机、子系统和零部件等多源层次信息的建模分析，此时整机级的可靠性数据可能较少。如果采用基于故障时间数据的可靠性建模与评估方法则无法达到较高的评估精度；而采用基于多源层次信息集的可靠性建模与评估方法，一方面可以保证评估精度的要求，另一方面可进一步获得各子系统和零部件对系统可靠性的重要程度。基于状态监测数据的可靠性建模与评估本质上是对基于性能检测数据的可靠性建模与评估的拓展，前者主要是针对用户厂在实际工况下性能退化数据、工作环境和工作应力等数据的建模与分析，后者主要是针对主机厂在理想工况下的性能检测数据的建模与分析。

6.2 后续工作展望

本文在重型数控机床的可靠性建模与可靠性评估方面进行了探索研究。随着这些模型和方法在实际工程中的逐步应用以及数控机床逐渐向智能机床的不断发展，重型数控机床的可靠性建模与评估技术将会涌现出新的应用需求和挑战。在本论文的研究基础上，我们将继续针对重型数控机床在寿命周期各个阶段出现的可靠性建模与评估的问题与需求，沿着以下三个方向展开进一步的研究：

(1) 考虑多时变因素的多源信息融合评估方法

重型数控机床的可靠性受到寿命周期多个阶段的多个因素的影响，对其进行可靠性的实时评估，需要对寿命周期的多个影响因素进行全面考虑并对多源信息进行有效融合，在此基础上对可靠性进行实时的评估。多源信息的融合和多因素的考虑需在一个完整的框架下才能有效展开。因此，有待进一步拓展现有的层次多源信息融合框架并将其与多时变因素的建模框架进行整合，同时对新框架下的建模方法、评估技术和实现算法重点突破，从而构建数控机床考虑多时变因素的多源信息融合评估的方法体系。

(2) 融合退化试验、状态监测和任务工况信息的使用可靠性评估

设计研制阶段的性能退化试验数据、使用阶段的状态监测数据和任务工况信息是机床使用可靠性评估的主要数据来源。这些数据由于其来源的阶段性的特点，使其数据内容和数据形式具有差异性和时变性，并且从寿命周期发展的角度来看，这些信息同时也存在内在的耦合关系。如何在多源信息融合的框架下，将性能退化试验建模和状态监测建模进行“寿命周期阶段”维度上的耦合，将状态监测建模与任务工况信息建模进行“数据关联层次”维度上的耦合，以此来研究融合退化试验、状态监测和任务工况信息的可靠性建模与评估技术，有待深入研究。

(3) 新型实时评估算法的研究以及可靠性建模与评估方法的系统软件实现

随着数控机床向着智能化方向的发展，机床的状态监控和健康管理逐渐成为使用阶段机床可靠性保证的关键手段，并将对使用可靠性评估的实时性提出更高的要求。数控机床的使用可靠性评估具有多性能退化、多时变因素和多信息来源的特点，模型结构复杂、输入信息繁多，实时的评估要求对算法的计算效率要求极高。贝叶斯框架下经典的马尔科夫链蒙特卡洛方法已经难以实现高效率的实时评估计算。因此，亟需研究新型的实时评估算法以应对这一需求，并在此基础上研究可靠性建模与评估方法的系统软件实现，以期在数控机床向智能机床转变时将可靠性建模与评估的系统软件集成为智能装备软件系统的一部分。目前，在这方面尚为空白，还有待耕耘开拓。

致 谢

“宝剑锋从磨砺出，梅花香自苦寒来”，经历博士三年多的学习和专研，在这篇饱含着导师、师长、学友、亲人和自己心血的博士论文完稿之时，心情无比的激动和澎湃！

首先我想对我敬爱的导师黄洪钟教授致以由衷的感谢！感谢黄洪钟教授六年多来对我在为人、做事、科研和学术上的耐心教育、悉心指导、严格要求和倾心培养。回顾六年多的时间，我从一个彷徨在科研和学术之门的外行人，锻炼成了一个在科研上独立自主在学术上敢于创新的博士生。这期间无不灌注着导师黄洪钟教授高瞻远瞩的指导和细致入微的培养。黄洪钟教授一丝不苟的治学态度、精益求精的敬业精神、宽以待人而严于律己的处世风格，都潜移默化的影响着我、激励着我不断向前奋进。在博士阶段即将完满结束，学术、科研和人生事业即将开启新篇章之际，对黄洪钟教授致以我最崇高的敬意和最深切的感谢！

特别感谢加州大学洛杉矶分校 Mosleh 教授！感谢他给我提供了宝贵的学习和研究的平台和资源，感谢他在我留学期间在学术研究上给与的启发和指导，感谢他为我研究的拓展创造的宝贵条件，让我道路更宽、动力更足。

感谢 M. J. Zuo 教授、M. Xie 教授、T. Jin 教授在我论文撰写期间给与的指导和帮助。

感谢电子科技大学可靠性工程研究所的刘宇老师、汪忠来老师、朱顺鹏老师、李海庆老师、许焕卫老师、李彦锋老师、孟德彪老师、凌丹老师、何丽萍老师、陈中柘老师、张小玲老师和邱静老师等，感谢他们在我生活、学习、科研和学术研究中提供的关怀和帮助，是他们让我获益良多快速成长。真心的感谢我的同门们，感谢张旭东、庞煜、肖宁聪、杨圆鉴、肖振林、孙健、吕志强、王海琨、付国忠、张小强、刘征、左芳君、高会英、米金华等，感谢他们在这一路中的协作、支持、分享与陪伴。

感谢在美国留学期间的 Mihai Diaconeasa, Samaneh Balali, Marilia Ramos, 汪洋、张敏、胡薇薇、王琛等朋友，是他们让我在他国异乡感到友谊的温暖和伙伴的力量。

衷心感谢参加论文评阅和答辩的教授和专家，感谢他们的肯定、支持和鼓励！

最后，深切地感谢我的父亲、母亲和爱人，感谢父母的养育之恩，感谢爱人的珍爱之情，他们给了我最深切的关怀、最温暖的支持和最无私的爱，让我不惧风雨、勇往直前！

参考文献

- [1] 中国机床工具工业协会. 机床工具行业“十二五”发展规划(一)[J]. 金属加工(冷加工), 2011, (16): 34-38.
- [2] 中国机床工具工业协会. 机床工具行业“十二五”发展规划(二)[J]. 金属加工(冷加工), 2011, (17): 33-35.
- [3] 中国机床工具工业协会. 机床工具行业“十二五”发展规划(三)[J]. 金属加工(冷加工), 2011, (18): 35-37.
- [4] 国务院. 国务院关于印发《中国制造 2025》的通知[EB/OL]. http://www.gov.cn/gongbao/content/2015/content_2873744.htm, 2015.
- [5] J. R. W. Merrick, R. Soyer, T. A. Mazzuchi. A Bayesian semiparametric analysis of the reliability and maintenance of machine tools[J]. *Technometrics*, 2003, 45(1): 58-69.
- [6] J. P. Kharoufeh, S. M. Cox, M. E. Oxley. Reliability of manufacturing equipment in complex environments[J]. *Annals of Operations Research*, 2013, 209(1): 231-254.
- [7] A. Verl, U. Heisel, M. Walther, et al. Sensorless automated condition monitoring for the control of the predictive maintenance of machine tools[J]. *CIRP Annals-Manufacturing Technology*, 2009, 58(1): 375-378.
- [8] M. Mori, M. Fujishima. Remote monitoring and maintenance system for CNC machine tools[J]. *Procedia CIRP*, 2013, 12: 7-12.
- [9] G. M. Martinov, A. B. Ljubinov, L. I. Martinova, et al. Remote machine tool control and diagnostic based on web technologies[C]. *Proceedings of the International Conference on Competitive Manufacturing 2013 (COMA' 13)*, Stellenbosch, South Africa, 2013.
- [10] 杨建国, 王智明, 王国强, 等. 数控机床可靠性指标的似然比检验区间估计[J]. *机械工程学报*, 2012, 48(2): 9-15.
- [11] 杨兆军, 李小兵, 许彬彬, 等. 加工中心时间动态可靠性建模[J]. *机械工程学报*, 2012, 48(2): 16-22.
- [12] 张根保, 李冬英, 刘杰, 等. 面向不完全维修的数控机床可靠性评估[J]. *机械工程学报*, 2013, 49(23): 136-141.
- [13] 吴军, 邵新宇, 邓超, 等. 基于性能劣化的可靠性预测与系统开发[J]. *计算机集成制造系统*, 2011, 17(1): 191-197.
- [14] 邓超, 孙耀宗, 李嵘, 等. 基于隐 Markov 模型的重型数控机床健康状态评估[J]. *计算机集成制造系统*, 2013, 19(3): 552-558.

- [15] W. Peng, H. Z. Huang, Y. F. Li, et al. Life cycle reliability assessment of new product-A Bayesian model updating approach[J]. *Reliability Engineering and System Safety*, 2013, 112: 109-119.
- [16] 张义民. 数控机床可靠性技术评述(上)[J]. *世界制造技术与装备市场*, 2012, (5): 49-57.
- [17] 张义民. 数控机床可靠性技术评述(下)[J]. *世界制造技术与装备市场*, 2012, (6): 56-67.
- [18] 杨兆军, 陈传海, 陈菲, 等. 数控机床可靠性技术的研究进展[J]. *机械工程学报*, 2013, 49(20): 130-139.
- [19] 张根保, 王立平. 国产数控机床可靠性技术综述[J]. *航空制造技术*, 2013, (5): 26-31.
- [20] 何正嘉, 曹宏瑞, 訾艳阳, 等. 机械设备运行可靠性评估的发展与思考[J]. *机械工程学报*, 2014, 50(2): 171-186.
- [21] 张小丽, 陈雪峰, 李兵, 等. 机械重大装备寿命预测综述[J]. *机械工程学报*, 2011, 47(11): 100-116.
- [22] A. Z. Keller, A. R. R. Kamath, U. D. Perera. Reliability analysis of CNC machine tools[J]. *Reliability Engineering*, 1982, 3: 449-473.
- [23] Y. Jia, M. Wang, Z. Jia. Probability distribution of machining center failures[J]. *Reliability Engineering and System Safety*, 1995, 50: 121-125.
- [24] Y. Wang, Y. Jia, J. Yu, et al. Failure probabilistic model of CNC lathes[J]. *Reliability Engineering and System Safety*, 1999, 65: 307-314.
- [25] Y. Wang, Y. Jia, W. Jiang. Early failure analysis of machining centers: A case study[J]. *Reliability Engineering and System Safety*, 2001, 72(1): 91-97.
- [26] Y. Dai, Y. F. Zhou, Y. Z. Jia. Distribution of time between failures of machining center based on type I censored data[J]. *Reliability Engineering and System Safety*, 2003, 79(3): 377-379.
- [27] S. J. Almalki, S. Nadarajah. Modifications of the Weibull distribution: A review[J]. *Reliability Engineering and System Safety*, 2014, 124: 32-55.
- [28] D. N. P. Murthy, M. Xie, R. Jiang. *Weibull Models*[M]. Hoboken: John Wiley & Sons, 2004.
- [29] M. Xie, C. D. Lai. Reliability analysis using an additive Weibull model with bathtub-shaped failure rate function[J]. *Reliability Engineering and System Safety*, 1996, 52: 87-93.
- [30] H. Pham, C.-D. Lai. On recent generalizations of the Weibull distribution[J]. *IEEE Transactions on Reliability*, 2007, 56(3): 454-458.
- [31] M. Bebbington, C. D. Lai, R. Zitikis. A flexible Weibull extension[J]. *Reliability Engineering and System Safety*, 2007, 92(6), 719-726.
- [32] K. Sultan, M. A. Ismail, A. S. Al-Moisheer. Mixture of two inverse Weibull distributions: Properties and estimation[J]. *Computational Statistics & Data Analysis*, 2007, 51, 5377-5387.

- [33] W. Lu, D. Shi. A new compounding life distribution: the Weibull-Poisson distribution[J]. *Journal of Applied Statistics*, 2012, 39, 21-38.
- [34] T. Dimitrakopoulou, K. Adamidis, S. Loukas. A lifetime distribution with an upside-down bathtub-shaped hazard function[J]. *IEEE Transactions on Reliability*, 2007, 56(2), 308-311.
- [35] J. M. F. Carrasco, E. M. M. Ortega, G. M. Cordeiro. A generalized modified Weibull distribution for lifetime modeling[J]. *Computational Statistics & Data Analysis*, 2008, 53, 450-462.
- [36] G. D. C. Barriga, F. Louzada-Neto, V. G. Cancho. The complementary exponential power lifetime model[J]. *Computational Statistics & Data Analysis*, 2011, 55, 1250-1259.
- [37] G. O. Silva, E. M. M. Ortega, G. M. Cordeiro. The beta modified Weibull distribution[J]. *Lifetime data Analysis*, 2010, 16, 409-430.
- [38] P. F. Paranaíba, E. M. M. Ortega, G. M. Cordeiro, et al. The beta Burr XII distribution with application to lifetime data[J]. *Computational Statistics & Data Analysis*, 2011, 55, 1118-1136.
- [39] N. Singla, K. Jain, S. K. Sharma. The Beta generalized Weibull distribution: Properties and applications[J]. *Reliability Engineering and System Safety*, 2012, 102, 5-15.
- [40] 王智明. 数控机床的可靠性评估与不完全预防维修及其应用[D]. 上海: 上海交通大学, 2011.
- [41] 许彬彬. 基于维修程度的数控机床可靠性建模与分析[D]. 长春: 吉林大学, 2011.
- [42] 张根保, 李冬英, 刘杰等. 面向不完全维修的数控机床可靠性评估[J]. *机械工程学报*, 2013, 23: 136-141.
- [43] Z. J. Yang, C. H. Chen, F. Chen, et al. Reliability analysis of machining center based on the field data[J]. *Eksploatacja I Niezawodnosc - Maintenance and Reliability*, 2013; 15(2): 147-155.
- [44] T. R. Bennett, J. M. Booker, S. A. Keller-McNulty, et al. Testing the untestable: Reliability in the 21st century[J]. *IEEE Transactions on Reliability*, 2003, 52(1): 118-124.
- [45] S. A. Keller-McNulty, A. G. Wilson. Reliability for the 21st century[J]. *Mathematical and Statistical Methods in Reliability, Series on Quality, Reliability and Engineering*, eds. B. Lindqvist, K. Doksum. 2003, 7: 15-20.
- [46] 庄钊文, 郁文贤. 信息融合技术在可靠性评估中的应用[J]. *系统工程与电子技术*, 2000, 3: 75-77+80.
- [47] A. G. Wilson, T. L. Graves, M. S. Hamada, et al. Advances in data combination, analysis and collection for system reliability assessment[J]. *Statistical Science*, 2006, 21(4): 514-531.
- [48] C. M. Anderson-Cook. Opportunities and issues in multiple data type meta-analyses[J]. *Quality*

- Engineering, 2009, 21(3): 241-253.
- [49] D. V. Mastran. Incorporating component and system test data into the same assessment: A Bayesian approach[J]. Operations Research, 1976, 24(3), 491-499.
- [50] D. V. Mastran, N. D. Singpurwalla. A Bayesian estimation of the reliability of coherent structures[J]. Operations Research, 1978(4), 26: 663-672.
- [51] R. Barlow. Combining component and system information in system reliability calculation[M] Probabilistic Methods in the Mechanics of Solids and Structures, Eds. S. Eggwertz and N. L. Lind, Berlin: Springer-Verlag, 1985, 375-383.
- [52] H. Martz, R. Waller, E. Fickas. Bayesian reliability analysis of series systems of binomial subsystems and components[J]. Technometrics, 1988, 30(2): 143-154.
- [53] H. Martz, R. Waller. Bayesian reliability analysis of complex series/parallel systems of binomial subsystems and components[J] Technometrics, 1990, 32(4): 407-416.
- [54] A. E. Gelfand, A. F. M. Smith. Sampling-based approaches to calculating marginal densities[J]. Journal of the American statistical association, 1990, 85(410), 398-409.
- [55] A. F. M. Smith, G. O. Roberts. Bayesian computation via the Gibbs sampler and related Markov chain Monte Carlo methods[J]. Journal of the Royal Statistical Society. Series B (Methodological), 1993, 55(1): 3-23.
- [56] W. R. Gilks, S. Richardson, D. J. Spiegelhalter. Markov Chain Monte Carlo in Practice[M]. London: Chapman & Hall, 1996.
- [57] V. E. Johnson, T. L. Graves, M. S. Hamada, et al. A hierarchical model for estimating the reliability of complex systems[J]. Bayesian Statistics, 2003, 7: 199-213.
- [58] M. Hamada, H. F. Martz, C. Shane Reese, et al. A fully Bayesian approach for combining multilevel failure information in fault tree quantification and optimal follow-on resource allocation[J]. Reliability Engineering and System Safety, 2004, 86(3): 297-305.
- [59] T. L. Graves, M. S. Hamada. A demonstration of modern Bayesian methods for assessing system reliability with multilevel data and for allocating resources[J]. International Journal of Quality, Statistics, and Reliability, 2009, 1-10.
- [60] C. M. Anderson-Cook, T. Graves, N. Hengartner, et al. Reliability modeling using both system test and quality assurance data[J]. Journal of the Military Operations Research Society, 2008, 13: 5-18.
- [61] C. Shane Reese, A. G. Wilson, J. Q. Guo, et al. A Bayesian model for integrating multiple sources of lifetime information in system-reliability assessments[J]. Journal of Quality Technology, 2011, 43(2): 127-141.

- [62] A. Wilson, C. M. Anderson-Cook, A. Huzurbazar. A case study for quantifying system reliability and uncertainty[J]. *Reliability Engineering and System Safety*, 2011, 96(9): 1076-1084.
- [63] C. M. Anderson-Cook, S. Crowder, A. Huzurbazar, et al. Quantifying reliability uncertainty from catastrophic and margin defects: A proof of concept[J]. *Reliability Engineering and System Safety*, 2011, 96(9): 1063-1075.
- [64] C. Jackson, A. Mosleh. Bayesian inference with overlapping data for systems with continuous life metrics[J]. *Reliability Engineering and System Safety*, 2012, 106: 217-231.
- [65] J. Guo, A. Wilson. Bayesian methods for estimating the reliability of complex systems using heterogeneous multilevel information[J]. *Technometrics*, 2013 55(4): 461-472.
- [66] W. Peng, H. Z. Huang, M. Xie, et al. A Bayesian approach for system reliability analysis with multilevel pass-fail, lifetime and degradation data sets[J]. *IEEE Transactions on Reliability*, 2013, 62(3): 689-699.
- [67] W. Q. Meeker, L. A. Escobar. A review of recent research and current issues in accelerated testing[J]. *International Statistical Review*, 1993, 61(1): 147-168.
- [68] W. Q. Meeker, L. A. Escobar. *Statistical Methods for Reliability Data*[M]. New York, John Wiley & Sons, 1998.
- [69] W. Q. Meeker, L. A. Escobar, C. J. Lu. Accelerated degradation tests: Modeling and analysis[J]. *Technometrics*, 1998, 40(2): 89.
- [70] A. K. S. Jardine, D. Lin, D. Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance[J]. *Mechanical Systems and Signal Processing* 2006, 20(7): 1483-1510.
- [71] J. M. van Noortwijk. A survey of the application of gamma processes in maintenance[J]. *Reliability Engineering and System Safety*, 2007, 94(1): 2-21.
- [72] C. Y. Peng, S. T. Tseng. Progressive-stress accelerated degradation test for highly-reliable products[J]. *IEEE Transactions on Reliability*, 2010, 59(1): 30-37.
- [73] Z.-S. Ye, M. Xie. Stochastic modelling and analysis of degradation for highly reliable products[J]. *Applied Stochastic Models in Business and Industry*, 2014, 31(1): 16-32.
- [74] K. A. Doksum, A. Høyland. Models for variable-stress accelerated life testing experiments based on Wiener processes and the inverse Gaussian distribution[J]. *Technometrics*, 1992, 34(1):74-82.
- [75] C. J. Lu, W. O. Meeker. Using degradation measures to estimate a time-to-failure distribution[J]. *Technometrics*, 1993, 35(2): 161-174.

- [76] G. Whitmore, F. Schenkelberg. Modelling accelerated degradation data using Wiener diffusion with a time scale transformation[J]. *Lifetime Data Analysis*, 1997, 3(1): 27-45.
- [77] Y. Wang, Z. S. Ye, K. L. Tsui. Stochastic evaluation of magnetic head wears in hard disk drives[J]. *IEEE Transactions on Magnetism*, 2014, 50(5): 1-7.
- [78] C. Park, W. Padgett. New cumulative damage models for failure using stochastic processes as initial damage[J]. *IEEE Transactions on Reliability*, 2005, 54(3):530-540.
- [79] C. Park, W. Padgett. Accelerated degradation models for failure based on geometric Brownian motion and gamma processes[J]. *Lifetime Data Analysis*, 2005, 11(4): 511-527.
- [80] C. Park, W. Padgett. Stochastic degradation models with several accelerating variables[J]. *IEEE Transactions on Reliability*, 2006, 55(2): 379-390.
- [81] S. J. Bae, W. Kuo, P. H. Kvam. Degradation models and implied lifetime distributions[J]. *Reliability Engineering and System Safety*, 2007, 92(5): 601-608.
- [82] W. J. Padgett, M. A. Tomlinson. Inference from accelerated degradation and failure data based on Gaussian process models[J]. *Lifetime Data Analysis* 2004, 10(2):191-206.
- [83] C. C. Tsai, S. T. Tseng, N. Balakrishnan. Optimal design for degradation tests based on gamma processes with random effects[J]. *IEEE Transactions on Reliability* 2012, 61(1): 604-613.
- [84] V. R. Joseph, I. T. Yu. Reliability improvement experiments with degradation data[J]. *IEEE Transactions on Reliability*, 2006, 55(1): 149-157.
- [85] H. Liao, E. A. Elsayed. Reliability inference for field conditions from accelerated degradation testing[J]. *Naval Research Logistics*, 2006, 53(6): 576-587.
- [86] V. Bagdonavičius, M. Nikulin. Statistical models to analyze failure, wear, fatigue, and degradation data with explanatory variables[J]. *Communications in Statistics—Theory and Methods*, 2009, 38(16-17): 3031-3047.
- [87] Z. S. Ye, Y. Hong, Y. Xie. How do heterogeneities in operating environments affect field failure predictions and test planning[J]. *The Annals of Applied Statistics*, 2013, 7(4): 2249-2271.
- [88] W. Peng, Y. F. Li, Y. J. Yang, et al. Leveraging degradation testing and condition monitoring for field reliability analysis with time-varying operating missions[J]. *IEEE Transactions on Reliability*, 2015, 64(4): 1367-1382.
- [89] N. Z. Gebraeel, M. A. Lawley, R. Li, et al. Residual-life distributions from component degradation signals: A Bayesian approach[J]. *IEEE Transactions*, 2005, 37(6): 543-557.
- [90] X. S. Si, W. B. Wang, C. H. Hu, et al. Remaining useful life estimation-A review on the statistical data driven approaches[J]. *European Journal of Operational Research*, 2011, 213(1): 1-14.

- [91] N. Chen, K. L. Tsui. Condition monitoring and remaining useful life prediction using degradation signals: revisited[J]. IIE Transactions, 2013, 45(9): 939-952.
- [92] N. Gebraeel, J. Pan. Prognostic degradation models for computing and updating residual life distributions in a time-varying environment[J]. IEEE Transactions on Reliability, 2008, 57(4): 539-550.
- [93] W. Q. Meeker, L. A. Escobar, Y. Hong. Using accelerated life tests results to predict product field reliability[J]. Technometrics, 2009, 51(2): 146-161.
- [94] L. Z. Wang, R. Pan, X. Y. Li, et al. A Bayesian reliability evaluation method with integrated accelerated degradation testing and field information[J]. Reliability Engineering and System Safety, 2013, 112: 38-47.
- [95] H. Liao, Z. Tian. A framework for predicting the remaining useful life of a single unit under time-varying operating conditions[J]. IIE Transactions, 2013, 45(9): 964-980.
- [96] W. Q. Meeker, Y. Hong. Reliability meets big data: Opportunities and challenges[J]. Quality Engineering, 2014, 26(1): 102-116.
- [97] H. Pham, H. Z. Wang. Imperfect maintenance[J]. European Journal of Operational Research, 1996; 94(3): 425-438.
- [98] L. Doyen, O. Gaudoin. Classes of imperfect repair models based on reduction of failure intensity or virtual age[J]. Reliability Engineering and System Safety, 2004; 84(1): 45-56.
- [99] S. Wu, M. J. Zuo. Linear and nonlinear preventive maintenance models[J]. IEEE Transactions on Reliability, 2010; 59(1): 242-249.
- [100] M. Kijima, H. Morimura, Y. Suzuki. Periodical replacement problem without assuming minimal repair[J]. European Journal of Operational Research, 1988, 37(2): 194-203.
- [101] M. Kijima. Some results for repairable systems with general repair[J]. Journal of Applied Probability, 1989, 26(1): 89-102.
- [102] E. L. Droguett, A. Mosleh. Bayesian methodology for model uncertainty using model performance data[J]. Risk Analysis, 2008, 28(5): 1457-1476.
- [103] R. Kazemi, A. Mosleh. Improving default risk prediction using Bayesian model uncertainty techniques[J]. Risk Analysis, 2012, 32(11): 1888-1900.
- [104] E. L. Droguett, A. Bayesian treatment of model uncertainty for partially applicable models[J]. Risk Analysis, 2014, 34(2): 252-270.
- [105] T. Zhang, R. Dwight. Choosing an optimal model for failure data analysis by graphical approach[J]. Reliability Engineering and System Safety, 2013, 115: 111-123.
- [106] D. M. Louit, R. Pascual, A. K. S. Jardine. A practical procedure for the selection of

- time-to-failure models based on the assessment of trends in maintenance data[J]. *Reliability Engineering and System Safety*, 2009, 94: 1618-1628.
- [107] K. P. Burnham, D. R. Anderson. Multimodel inference understanding AIC and BIC in model selection[J]. *Sociological Methods & Research*, 2004, 33: 261-304.
- [108] J. A. Hoeting, D. Madigan, A. E. Raftery, et al. Bayesian model averaging: A tutorial[J]. *Statistical Science*, 1999, 14(4): 382-401.
- [109] R. B. O'Hara, M. J. Sillanpaa. A review of Bayesian variable selection methods: What, how and which[J]. *Bayesian Analysis*, 2009, 4(1): 85-118.
- [110] I. Park, R. V. Grandhi. A Bayesian statistical method for quantifying model form uncertainty and two model combination methods[J]. *Reliability Engineering and System Safety*, 2014, 129: 46-56.
- [111] L. Kuo, T. Y. Yang. Bayesian computation for nonhomogeneous Poisson processes in software reliability[J]. *Journal of the American Statistical Association*, 1996, 91(434): 763-773.
- [112] G. Pulcini. Modeling the failure data of a repairable equipment with bathtub type failure intensity[J]. *Reliability Engineering and System Safety*, 2001, 71(2): 209-218.
- [113] A. O'Hagan, C. E. Buck, A. Daneshkhah, et al. *Uncertain Judgements: Eliciting Experts' Probabilities*[M]. Chichester: John Wiley & Sons, 2006.
- [114] J. Quigley, G. Hardman, T. Bedford, et al. Merging expert and empirical data for rare event frequency estimation: Pool homogenization for empirical Bayes models[J]. *Reliability Engineering and System Safety*, 2011, 96(6): 687-695.
- [115] L. Walls, J. Quigley. Building prior distributions to support Bayesian reliability growth modelling using expert judgement[J]. *Reliability Engineering and System Safety*, 2001, 74(2): 117-128.
- [116] W. Peng, H. Z. Huang, M. Xie, et al. A Bayesian approach for system reliability analysis with multilevel pass-fail, lifetime and degradation data sets[J]. *IEEE Transactions on Reliability*, 2013, 62(3): 689-699.
- [117] 张尧庭, 陈汉峰. 贝叶斯统计推断[M]. 北京: 科学出版社, 1991.
- [118] 茆诗松. 贝叶斯统计[M]. 北京: 中国统计出版社, 1999.
- [119] J. O. Berger. *Statistical Decision Theory and Bayesian Analysis, Second Edition*[M]. New York: Springer, 1993.
- [120] W. R. Gilks, S. Richardson, D. J. Spiegelhalter. *Markov Chain Monte Carlo in Practice*[M]. Boca Raton: Chapman & Hall/CRC, 1996.
- [121] D. Gamerman, H. F. Lopes. *Markov Chain Monte Carlo: Stochastic Simulation for Bayesian*

- Inference, Second Edition[M]. Boca Raton: Chapman & Hall/CRC, 2006.
- [122] M. S. Hamada, A. G. Wilson, C. S. Reese, et al. Bayesian Reliability[M]. New York: Springer, 2008.
- [123] A. E. Gelfand, A. F. M. Smith. Sampling-based approaches to calculating marginal densities[J]. Journal of the American Statistical Association, 1990, 85(410): 398-409.
- [124] A. F. M. Smith, G. O. Roberts. Bayesian computation via the Gibbs sampler and related Markov chain Monte Carlo methods[J]. Journal of the Royal Statistical Society. Series B (Methodological), 1993, 55(1): 3-23.
- [125] J. K. Kruschke. Doing Bayesian Data Analysis: A Tutorial with R and BUGS[M]. Oxford: Academic Press, 2011.
- [126] D. Lunn, D. Spiegelhalter, A. Thomas, N. Best. The BUGS project: Evolution, critique and future directions (with discussion)[J]. Statistics in Medicine, 2009, 28: 3049--3082.
- [127] I. Ntzoufras. Bayesian Modeling Using WinBUGS[M]. Hoboken: John Wiley & Sons, 2009.
- [128] J. Pearl. Probabilistic Reasoning in Intelligent Systems[M]. San Francisco: Morgan Kaufmann. 1988.
- [129] 张连文. 贝叶斯网引论[M]. 北京: 科学出版社, 2006.
- [130] J. Sigurdsson, L. Walls, J. Quigley. Bayesian belief nets for managing expert judgement and modelling reliability[J]. Quality and Reliability Engineering International, 2011, 17: 181-190.
- [131] M. Bensi, A. D. Kiureghian, D. Straub. Efficient Bayesian network modeling of systems[J]. Reliability Engineering and System Safety, 2013, 112: 200-213.
- [132] H. Boudali, J. B. Dugan. A continuous-time Bayesian network reliability modeling, and analysis framework[J]. IEEE Transactions on Reliability, 2006, 55(1): 86-97.
- [133] A. G. Wilson, A. V. Huzurbazar. Bayesian networks for multilevel system reliability[J]. Reliability Engineering and System Safety, 2007, 92(10): 1413-1420.
- [134] B. Cai, Y. Liu, Z. Liu, et al. Using Bayesian networks in reliability evaluation for subsea blowout preventer control system[J]. Reliability Engineering and System Safety, 2012, 108: 32-41.
- [135] H. Langseth, L. Portinale. Bayesian networks in reliability[J]. Reliability Engineering and System Safety, 2007, 92: 92-108.
- [136] P. Weber, G. Medina-Oliva, C. Simon, et al. Overview on Bayesian networks applications for dependability, risk analysis and maintenance areas[J]. Engineering Applications of Artificial Intelligence, 2012, 25: 671-82.
- [137] A. O'Hagan, C. E. Buck, A. Daneshkhah, et al. Uncertain Judgements: Eliciting Experts'

- Probabilities[M]. Chichester: John Wiley & Sons; 2006.
- [138] T. Bedford, J. Quigley, L. Walls. Expert elicitation for reliable system design[J]. *Statistical Science*, 2006, 21(4): 428-450.
- [139] H. Gutierrez-Pulido H, V. Aguirre-Torres, J. A. Christen. A practical method for obtaining prior distributions in reliability[J]. *IEEE Transactions on Reliability*, 2005, 54(2): 262-269.
- [140] D. G. Seth. Formulating informative, data-based priors for failure probability estimation in reliability analysis[J]. *Reliability Engineering and System Safety*, 2007, 92(4): 490-502.
- [141] W. Peng, H. Z. Huang, Y. Li, et al. Life cycle reliability assessment of new products—A Bayesian model updating approach[J]. *Reliability Engineering and System Safety*, 2013, 112: 109-119.
- [142] Agena Ltd. AgenaRisk software package[EB/OL]. <http://www.AgenaRisk.com/S>, 2007.
- [143] M. Neil, M. Taylor, D. Marquez. Inference in hybrid Bayesian networks using dynamic discretization[J]. *Statistics and Computing*, 2007, 17(3): 219-233.
- [144] D. Marquez, M. Neil, N. Fenton. Improved reliability modeling using Bayesian networks and dynamic discretization[J]. *Reliability Engineering and System Safety*, 2010, 95: 412-425.
- [145] N. Fenton, M. Neil. Risk assessment and decision analysis with Bayesian networks[M]. Boca Raton: CRC Press, Taylor & Francis Group, 2012.
- [146] Y. Shi, W. Q. Meeker. Bayesian methods for accelerated destructive degradation test planning[J]. *IEEE Transactions on Reliability*, 2012, 61: 245-53.
- [147] S. H. Mohammadian, D. Ait-Kadi, F. Routhier. Quantitative accelerated degradation testing: Practical approaches[J]. *Reliability Engineering and System Safety*, 2010, 95: 149-59.
- [148] Z. S. Ye, M. Xie, Y. Shen, et al. Degradation-based burn-in planning under competing risks[J]. *Technometrics*, 2012, 54: 159-68.
- [149] Z. Chen, S. Zheng. Lifetime distribution based degradation analysis[J]. *IEEE Transactions on Reliability*, 2005, 54: 3-10.
- [150] M. Guida, G. Pulcini. The inverse gamma process: A family of continuous stochastic models for describing state-dependent deterioration phenomena[J]. *Reliability Engineering and System Safety*, 2013, 120: 72-79.
- [151] Z. Xu, Y. Ji, D. Zhou. Real-time reliability prediction for a dynamic system based on the hidden degradation process identification[J]. *IEEE Transactions on Reliability*, 2008, 57: 230-42.
- [152] J. Lawless, M. Crowder. Covariates and random effects in a gamma process model with application to degradation and failure[J]. *Lifetime Data Analysis*, 2004, 10: 213-27.

- [153] Z. Ye, M. Xie, L. Tang, et al. Efficient semiparametric estimation of gamma processes for deteriorating products[J]. *Technometrics*, 2014, 56(4): 504-513.
- [154] Z. S. Ye, K. L. Tsui, Y. Wang, et al. Degradation data analysis using Wiener processes with measurement errors[J]. *IEEE Transactions on Reliability*, 2013, 64(2): 772-780.
- [155] W. Peng, Y. F. Li, Y. J. Yang, et al. Inverse Gaussian process models for degradation analysis: A Bayesian perspective[J]. *Reliability Engineering and System Safety*, 2014, 130: 175-189.
- [156] S. Tang, C. Yu, X. Wang, et al. Remaining useful life prediction of lithium-ion batteries based on the wiener process with measurement error[J]. *Energies*, 2014, 7(2):520-547.
- [157] X. Wang. Wiener processes with random effects for degradation data[J]. *Journal of Multivariate Analysis*, 2010, 101(2): 340-351.
- [158] T. R. Tsai, C. W. Lin, Y. L. Sung, et al. Inference from lumen degradation data under Wiener diffusion process[J]. *IEEE Transactions on Reliability*, 2012, 61(3): 710-718.
- [159] X. Wang, D. Xu. An inverse Gaussian process model for degradation data[J]. *Technometrics*, 2010, 52(2): 188-197.
- [160] Z. S. Ye, N. Chen. The inverse Gaussian process as a degradation model[J]. *Technometrics*, 2014, 56(3): 302-311.
- [161] C. Peng. Inverse Gaussian processes with random effects and explanatory variables for degradation data[J]. *Technometrics*, 2014, 57(1): 100-111.
- [162] 孟光, 尤明懿. 基于状态监测的设备寿命预测与预防维护规划研究进展[J]. *振动与冲击*, 2011, 30(8): 1-11.
- [163] P. Wang, D. W. Coit. Reliability prediction based on degradation modeling for systems with multiple degradation measures[C]. *Reliability and Maintainability, 2004 Annual Symposium-RAMS*, 2004, 302-307.
- [164] J. K. Sari, M. J. Newby, A.C. Brombacher, et al. Bivariate constant stress degradation model: LED lighting system reliability estimation with two-stage modelling[J] *Quality Reliability Engineering International*, 2009, 25: 1067-1084.
- [165] Z. Pan, N. Balakrishnan. Reliability modeling of degradation of products with multiple performance characteristics based on gamma processes[J]. *Reliability Engineering and System Safety*, 2011, 96(8): 949-957.
- [166] Z. Pan, N. Balakrishnan, Q. Sun, et al. Bivariate degradation analysis of products based on Wiener processes and copulas[J] *Journal of Statistical Computation and Simulation*, 2013, 83(7): 1316-1329.
- [167] X. Wang, B. Guo, J. Cheng. Residual life estimation based on bivariate Wiener degradation

- process with time-scale transformations[J]. *Journal of Statistical Computation and Simulation*, 2014, 84(3): 545-563.
- [168] X. Wang, N. Balakrishnan, B. Guo. Residual life estimation based on nonlinear-multivariate Wiener process[J]. *Journal of Statistical Computation and Simulation*, 2015, 85(9): 1742-1764.
- [169] U. Cherubini, E. Luciano, W. Vecchiato. *Copula Method in Finance*[M]. Chichester: John Wiley & Sons, 2004.
- [170] R. B. Nelsen. *An Introduction to Copulas*[M]. New York: Springer, 2006.
- [171] N. Z. Gebraeel, M. A. Lawley, R. Li, et al. Residual-life distributions from component degradation signals: A Bayesian approach[J]. *IIE Transactions*, 2005, 37(6): 543-557.

在学期间参与的项目研究

- [1] “高档数控机床与基础制造装备”国家科技重大专项课题“高速龙门五轴加工中心（AC 摆角），课题编号：2009ZX04002-013”子课题：高速龙门五轴加工中心整机可靠性研究。
- [2] “高档数控机床与基础制造装备”国家科技重大专项课题“重型数控机床关键共性技术创新能力平台”，课题编号：2013ZX04013-011”子课题：重型数控机床可靠性评价及热变形分析共性技术研究与应用，子课题编号：2013ZX04013-011-05。
- [3] “高档数控机床与基础制造装备”国家科技重大专项课题“重型机床可靠性评价与试验方法研究”，课题编号：2014ZX04014-011”子课题：重型机床电器控制与驱动系统可靠性技术研究，子课题编号：2014ZX04014-011-01。
- [4] 国家自然科学基金委和中国工程物理研究院联合基金项目：基于混合不确定性信息处理的复杂分层系统健康评估，项目编号：U13301055。
- [5] 国家自然科学基金项目：数控装备运行可靠性的多源时变耦合建模与实时评估研究，项目编号：51405065。

在学期间发表和录用的学术论文

- [1] W. Peng, H. Z. Huang, M. Xie, et al. A Bayesian approach for system reliability analysis with multilevel pass-fail, lifetime and degradation data sets[J]. IEEE Transactions on Reliability, 2013, 62(3): 689-699. (SCI)
- [2] W. Peng, H. Z. Huang, Y. Li, et al. Life cycle reliability assessment of new products—A Bayesian model updating approach[J]. Reliability Engineering and System Safety, 2013, 112: 109-119. (SCI)
- [3] W. Peng, Y. Liu, Y. F. Li, et al. A Bayesian optimal design for degradation tests based on the inverse Gaussian process[J]. Journal of Mechanical Science and Technology, 2014, 28(10): 3937-3946. (SCI)
- [4] W. Peng, Y. F. Li, Y. J. Yang, et al. Inverse Gaussian process models for degradation analysis: A Bayesian perspective[J]. Reliability Engineering and System Safety, 2014, 130: 175-189. (SCI)
- [5] W. Peng, Y. F. Li, Y. J. Yang, et al. Leveraging degradation testing and condition monitoring for field reliability analysis with time-varying operating missions[J]. IEEE Transactions on Reliability, 2015, 64(4): 1367-1382. (SCI)
- [6] W. Peng, Y. F. Li, Y. J. Yang, et al. Bivariate analysis of incomplete degradation observations based on inverse Gaussian processes and copulas[J]. IEEE Transactions on Reliability, DOI: 10.1109/TR.2015.2513038. (SCI, 已录用)
- [7] 彭卫文, 黄洪钟, 李彦锋, 等. 基于数据融合的加工中心功能铣头贝叶斯可靠性评估[J]. 机械工程学报, 2014, 50(6): 185-191. (EI)
- [8] Y. J. Yang, W. Peng, D. Meng, et al. Reliability analysis of direct drive electrohydraulic servo valves based on a wear degradation process and individual differences[J]. Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability, 2014, 228: 621-630. (SCI)
- [9] H. Z. Huang, P. L. Cui, W. Peng, et al. Fatigue lifetime assessment of aircraft engine disc via multi-source information fusion[J]. International Journal of Turbo & Jet-Engines, 2014, 31(2): 167-174. (SCI)
- [10] S. P. Zhu, H. Z. Huang, W. Peng, et al. Probabilistic physics of failure-based framework for fatigue life prediction of aircraft gas turbine discs under uncertainty[J]. Reliability Engineering and System Safety, 2016, 146: 1-12. (SCI)
- [11] L. He, C. Yin, W. Peng, et al. Reliability and risk assessment of aircraft electric systems[J].

- Eksploratacja i Niezawodnosc - Maintenance and Reliability, 2014, 16(4): 497-506. (SCI)
- [12] W. Peng, H. Z. Huang, Z. Wang, et al. A study on Bayesian design of degradation tests with the inverse Gaussian Processes. 2013 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, QR2MSE 2013[C]. Sichuan, 2013, 870-872. (EI)
该会议论文荣获 QR2MSE 2013 大会最佳论文奖 (Best Paper Award)
- [13] W. Peng, H. Z. Huang, Z. Wang, et al. Degradation analysis using the inverse Gaussian process model with random effects: A Bayesian perspective[C]. ASME 2013 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference (ASME IDETC/CIE 2013), Portland, 2013. (EI)
- [14] W. Peng, H. Z. Huang, Y. F. Li, et al. Field reliability analysis of complex systems based on degradation testing and field information[C]. The 11th International Conference on Frontiers of Design and Manufacturing (ICFDM 2014), Nanjing, 2014.
- [15] W. Peng, Y. J. Yang, Y. F. Li, et al. Degradation analysis with inverse Gaussian process model considering an S-shaped degradation rate[C]. The 6th Asia-Pacific International Symposium on Advanced Reliability and Maintenance Modeling (APARM 2014), Sapporo, 2014.
- [16] W. Peng, Y. F. Li, J. Mi, et al. A Bayesian bivariate degradation analysis method for reliability analysis of heavy machine tools under dynamic conditions[C]. ASME 2015 International Mechanical Engineering Congress & Exposition (IMECE 2015), Houston, 2015.
- [17] W. Peng, Y. J. Yang, Y. F. Li, et al. Bayesian degradation analysis with inverse Gaussian process models under time-varying degradation rates [J]. (under the 3rd round revision, *IEEE Transactions on Reliability*)
- [18] W. Peng, Y. F. Li, J. Mi et al. Reliability of complex systems under dynamic conditions: A Bayesian multivariate degradation perspective [J]. (under the 1st round revision, *Reliability Engineering and System Safety*)

在学期间申请的专利

- [1] 许焕卫, 李伟, 李彦锋, 黄洪钟, 彭卫文, 张小玲, 孟德彪, 王胜. 基于变量相关的导弹与发动机一体化多学科设计优化方法. 中国, 发明专利, 专利申请号: 201510648484.5.
- [2] 肖宁聪, 李彦锋, 黄洪钟, 张小玲, 许焕卫, 杨圆鉴, 彭卫文. 一种混合不确定性下基于代理模型的结构可靠性分析方法. 中国, 发明专利, 专利申请号: 201510151288.7.
- [3] 黄洪钟, 付国忠, 刘宇, 李彦锋, 米金华, 罗大双, 张龙龙, 杨圆鉴, 彭卫文. 基于齐次坐标方法的微动台动态可靠性分析方法. 中国, 发明专利, 专利申请号: 201410820168.7.