

基于深度学习的高速率无源波分复用系统智能集成优化与性能预测研究

熊宽¹, 柴萍²

¹青岛光盈光电技术有限责任公司, 山东 青岛

²青岛大学计算机科学技术学院, 山东 青岛

收稿日期: 2026年4月16日; 录用日期: 2026年5月15日; 发布日期: 2026年6月16日

摘要

高速无源波分复用(WDM)系统在工程化集成与封装环节中,常面临性能参数漂移、耦合损耗难以精确管控以及故障定位过度依赖人工经验等瓶颈。为此,文章引入长短期记忆网络(LSTM),确立了一种新型的智能化系统集成框架。该方案立足于软件工程化设计理念,通过构建基于LSTM的时序预测与故障诊断模型,实现了对插入损耗、串扰及耦合效率等核心指标的精准刻画,并完成了对系统传输劣化与封装失效的自动辨识。经高速WDM实验平台及实测数据集验证,该方法不仅能够有效克服人工调试的随机性,显著提升系统的集成效率与稳定性,还为高可靠性光通信系统的智能化演进提供了理论依据与工程参考。

关键词

高速波分复用, 无源WDM系统, 深度学习, 性能预测, 故障诊断

Research on Intelligent Integration Optimization and Performance Prediction of High-Rate Passive WDM Systems Based on Deep Learning

Kuan Xiong¹, Ping Chai²

¹Qingdao Applied Photonic Technologies Co., Ltd., Qingdao Shandong

²College of Computer Science and Technology, Qingdao University, Qingdao Shandong

Received: April 16, 2026; accepted: May 15, 2026; published: June 16, 2026

文章引用: 熊宽, 柴萍. 基于深度学习的高速率无源波分复用系统智能集成优化与性能预测研究[J]. 仪器与设备, 2026, 14(2): 253-262. DOI: 10.12677/iae.2026.142030

Abstract

High-speed passive wavelength division multiplexing (WDM) systems frequently encounter critical bottlenecks in engineering integration and packaging, including performance parameter drift, inaccurate control of coupling loss, and over-reliance on manual experience for fault localization. To tackle these challenges, this paper introduces long short-term memory (LSTM) networks and proposes a novel intelligent system integration framework. Grounded in software engineering principles, the framework employs LSTM-based time-series prediction and fault diagnosis models to achieve precise characterization of key metrics such as insertion loss, crosstalk, and coupling efficiency, as well as automatic identification of transmission degradation and packaging failure. Validated on a high-speed WDM testbed using measured datasets, the proposed method effectively reduces the uncertainty caused by manual debugging, significantly improves system integration efficiency and stability, and provides a theoretical foundation and engineering reference for the intelligent development of highly reliable optical communication systems.

Keywords

High-Speed WDM, Passive WDM System, Deep Learning, Performance Prediction, Fault Diagnosis

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

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

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



Open Access

1. 高速率 WDM 系统集成概述

随着 5G/6G 承载网的持续演进及数据中心流量的井喷式增长, 具备更高传输带宽的 400G、800G 无源波分复用(WDM)系统已成为光通信领域的战略重心[1]。系统集成技术成熟度不仅直接决定了光传输的效率与稳定性, 更成为了决定其产业化落地的关键砝码。然而, 当前高速率 WDM 系统在工程化进程中仍受困于诸多技术瓶颈[2]。损耗波动是其核心痛点之一, 高速率场景下, 硅基 AWG 芯片的波导损耗、光纤与芯片的耦合损耗受温度变化、工艺偏差、环境应力等因素影响显著[3], 尤其是在 400G 及以上速率采用 PAM4 等高阶调制格式时, 信号容错度极低, 微小的损耗波动就会导致误码率急剧升高, 影响系统传输性能[4]; 一致性差则主要体现在批量生产的芯片与封装组件之间。由于硅光工艺参数波动、封装对准精度差异等问题, 不同批次甚至同一批次的器件性能存在明显偏差, 难以满足系统规模化集成的标准化要求; 调试复杂源于高速 WDM 系统集成涉及光学、硅光工艺、封装技术、电子电路等多领域协同, 传统调试依赖人工经验, 需对耦合参数、光路对准、信号适配等进行反复调试, 不仅耗时费力, 还难以保证调试精度; 缺乏智能优化则使得系统集成过程无法实现参数的自适应调整, 难以应对动态变化的工作环境, 也无法提前预判性能劣化趋势, 导致系统运维成本居高不下。

波分复用系统集成技术正朝着高速化、集成化、低成本方向快速演进。国际上, 欧美日韩等发达国家的企业与科研机构率先布局 400G/800G 高速 WDM 系统集成技术, 在硅基 AWG 芯片设计、高速封装工艺等方面处于领先地位, 通过采用 CMOS 兼容工艺实现硅光器件的高集成度量产, 同时探索弹性光网络(EON)与 WDM 系统的融合, 提升频谱利用效率, 但此类技术多聚焦于硬件器件的性能优化, 缺乏对系统集成全流程的工程化管控。国内方面, 随着光通信产业的快速发展, 科研机构与企业加大了高速 WDM 系统集成技术的研发投入, 在硅基光子学、高速封装等领域取得了一系列突破, 国产硅光芯片、光模块

的性能不断提升, 新建项目国产化芯片设备中标占比已突破 60%, 同时在数据中心互联、5G 前传网络等场景实现了部分高速 WDM 系统的落地应用, 但与国际先进水平相比, 仍存在核心工艺精度不足、系统集成一致性差、工程化量产能力薄弱等问题, 尤其在 1.6T 及以上超高速系统集成领域仍有较大差距。总体而言, 当前波分复用系统集成技术的研究重点集中在硬件器件的性能提升, 而对系统集成的工程化、智能化管控重视不足。

深度学习技术的快速发展为光通信系统的智能化升级提供了新的路径, 其在光通信领域的应用已逐步拓展, 成为当前的研究热点。国内外学者围绕深度学习在光通信系统中的应用开展了大量研究, 在光纤折射率测量、脉冲放大系统建模、信号处理等方面取得了显著成果[5], 例如燕山大学与清华大学的研究团队将 LSTM 模型与光纤干涉传感系统相结合, 突破了自由光谱范围的限制, 实现了高灵敏度、宽范围的折射率测量, 预测均方根误差低至 3.029×10^{-4} [6]。在高速 WDM 系统领域, 深度学习的应用主要集中在信号解调、故障检测等环节, 通过构建神经网络模型实现对传输信号的降噪、误码率优化, 以及对光纤损耗、模块故障等问题的识别[7], 但此类应用多局限于系统单一环节的优化, 尚未形成覆盖系统集成全流程的智能化方案。此外, 部分研究探索了深度学习在光网络资源调度中的应用, 利用强化学习模型优化频谱分配策略, 降低网络阻塞率, 但未涉及高速 WDM 系统集成过程中的参数优化与性能预测。

综合来看, 当前高速率 WDM 系统集成与深度学习应用的研究仍存在明显不足, 核心体现在两个方面: 一是缺乏完善的智能集成框架, 现有研究多将硬件器件优化与深度学习应用割裂开来, 未构建起“数据采集 - 模型训练 - 参数优化 - 性能验证”的全流程智能集成体系, 无法实现硅基 AWG 芯片设计、高速封装、系统调试等环节的协同优化, 难以解决集成过程中的损耗波动、一致性差、调试复杂等痛点[8]; 二是缺乏针对高速 WDM 系统的时序性能预测方法, 高速 WDM 系统的损耗、串扰、误码率等性能指标具有明显的时序变化特性, 受温度、工艺、环境等因素的动态影响, 而现有研究多采用静态分析方法, 未利用深度学习擅长处理时序数据的优势, 无法提前预判性能劣化趋势, 也难以实现集成参数的自适应调整, 导致系统集成效率与稳定性难以进一步提升。因此, 将 LSTM 等深度学习技术与软件工程化思想相结合, 构建高速率 WDM 系统智能集成框架, 实现时序性能预测与集成参数智能优化, 成为解决当前技术瓶颈、推动高速 WDM 系统工程化与产业化发展的关键方向。

2. 需求分析与方法实现

(一) 高速无源波分复用系统原理

高速无源波分复用系统是高速光通信传输的核心载体, 其核心原理是利用不同波长的光信号作为传输载体, 在单根光纤中实现多通道、大容量的信号并行传输, 无需额外的光放大或信号再生设备, 具有结构简单、功耗低、成本可控、可靠性高的优势, 适配 400G/800G 高速传输场景的应用需求。该系统的核心组成包括无源波分复用器, 如硅基 AWG 芯片、光纤链路、光发射模块、光接收模块四大部分, 其中硅基 AWG 芯片作为核心器件, 承担着多波长信号的合波与分波功能, 通过阵列波导的光程差实现不同波长信号的精准分离与合成, 其性能直接决定系统的插入损耗、串扰、通道一致性等关键指标。在高速传输场景中, 无源波分复用系统通过合理规划波长通道、优化光路设计, 实现多波长信号的高效传输, 有效提升光纤的频谱利用率, 解决高速光通信中大容量、长距离传输的核心需求, 为数据中心互联、5G/6G 承载网提供核心技术支撑。

(二) LSTM 深度学习基本原理

长短期记忆网络(LSTM)是循环神经网络的改进型模型, 核心优势是解决传统 RNN 在处理长时序数据时出现的梯度消失或梯度爆炸问题, 能够有效捕捉时序数据中的长期依赖关系, 非常适配高速无源波分复用系统性能指标的时序变化特性。LSTM 模型通过引入输入门、遗忘门、输出门三大核心结构, 实现对时

序信息的精准筛选与记忆: 遗忘门负责决定丢弃哪些历史信息, 输入门负责筛选并更新当前时刻的有效信息, 输出门负责控制当前时刻的信息输出, 三者协同工作, 使模型能够自适应学习时序数据中的动态变化规律。在本研究中, LSTM 模型主要用于处理高速 WDM 系统集成过程中采集的时序数据, 例如温度、插入损耗、耦合损耗、误码率等, 通过对历史时序数据的学习, 实现系统性能预测与故障诊断, 为系统集成的智能优化提供算法支撑。与传统机器学习模型相比, LSTM 模型对时序数据的拟合能力更强, 预测精度与诊断准确率更高, 能够更好地适应高速 WDM 系统动态变化的工作场景。LSTM 的框架结构如图 1 所示。

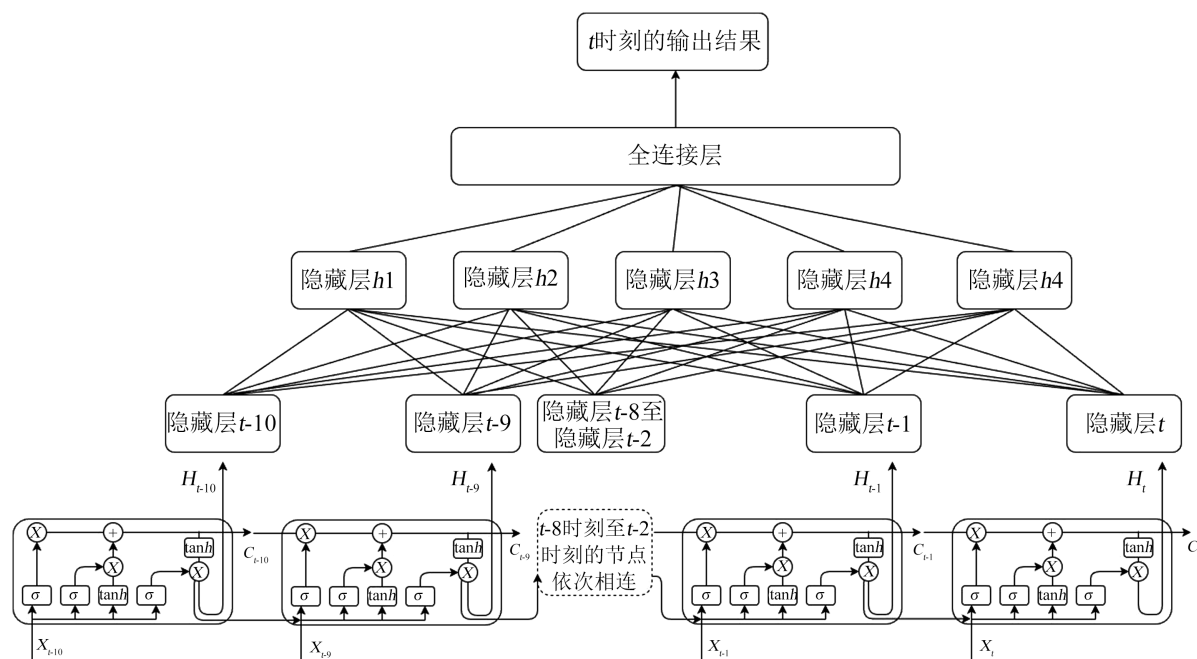


Figure 1. LSTM model structure

图 1. LSTM 模型结构

(三) 系统需求

结合高速无源波分复用系统集成的实际需求与软件工程化思想, 从功能、性能、工程三个维度明确系统需求, 为后续系统总体架构设计与工程实现提供依据, 确保系统设计贴合实际应用场景、满足工程化落地要求。

功能需求主要聚焦于系统集成的智能化升级, 核心包括三个方面: 一是智能预测功能, 能够基于历史时序数据, 精准预测高速 WDM 系统的插入损耗、耦合损耗、串扰、误码率等关键性能指标的变化趋势, 提前预判性能劣化风险; 二是故障诊断功能, 能够实时识别系统集成与运行过程中的常见故障, 包括耦合偏移、芯片劣化、光纤损耗增大、传输误码超标等, 明确故障类型与故障位置, 为故障排查提供支撑; 三是参数优化功能, 能够根据性能预测结果与故障诊断信息, 自适应调整系统集成参数, 如耦合对准参数、工艺参数等, 实现系统性能的动态优化, 解决损耗波动、一致性差等痛点。

性能需求主要保障系统的实用性与可靠性, 具体要求包括: 预测精度方面, 核心性能指标的预测误差不超过 3%, 确保预测结果具有实际指导意义; 诊断准确率方面, 常见故障的诊断准确率不低于 95%, 降低误判、漏判概率; 实时性方面, 数据采集、模型推理、结果输出的总延迟不超过 100 ms, 满足系统集成过程中动态调试与实时监控的需求。

工程需求主要围绕系统的工程化落地与规模化应用, 具体要求包括: 自动化集成需求, 能够实现硅

基 AWG 芯片封装、光路对准、参数调试等环节的自动化操作, 减少人工干预, 提升集成效率; 可部署需求, 系统能够适配不同的硬件平台与生产环境, 支持快速部署与调试, 降低工程化应用门槛; 可扩展需求, 系统采用模块化设计, 支持功能模块的灵活增减与技术迭代, 能够适配 1.6T 及以上超高速 WDM 系统的集成需求, 具备良好的扩展性。

(四) 系统总体架构设计

遵循软件工程化思想, 结合高速 WDM 系统智能集成的需求, 设计分层式系统总体架构, 实现“数据采集 - 模型训练 - 参数优化 - 应用落地”的全流程闭环, 架构整体分为四层, 从下至上依次为数据采集层、数据预处理层、LSTM 模型层、应用服务层, 各层采用模块化设计, 接口标准化, 确保系统的可复用性、可维护性与可扩展性。

数据采集层作为架构的基础, 主要负责采集高速 WDM 系统集成与运行过程中的各类时序数据。其采集内容主要包括三类: 一是硬件参数(如硅基 AWG 芯片的工艺与封装对准参数); 二是性能指标(如插入损耗、耦合损耗、串扰及误码率等); 三是环境参数(如温度、湿度和振动等)。该层通过传感器与测试仪器等设备实现数据的实时采集与存储, 在保障数据准确性与实时性的同时, 为后续的模型训练与优化提供坚实的数据支撑。

数据预处理层负责对采集到的原始数据进行处理, 解决原始数据中存在的噪声、缺失值、异常值等问题, 提升数据质量。具体处理流程包括数据标准化、平滑去噪、缺失值填充、时序滑窗处理等, 将原始数据转换为符合 LSTM 模型输入要求的标准化时序数据, 同时降低数据冗余, 提升模型训练效率, 确保模型输入数据的可靠性。

LSTM 模型层是系统的核心计算层, 基于预处理后的时序数据, 构建双 LSTM 模型, 分别实现性能预测与故障诊断功能, 同时集成模型训练与优化模块, 通过不断迭代优化模型超参数, 如隐藏层数量、学习率、迭代次数等, 提升模型的预测精度与诊断准确率。该层还负责模型的实时推理, 接收数据预处理层输出的标准化数据, 快速输出性能预测结果与故障诊断信息, 为应用服务层提供决策支撑。

应用服务层是系统的落地应用层, 基于 LSTM 模型层的输出结果, 实现三大核心应用功能: 性能预测可视化、故障报警与排查、集成参数自适应优化, 同时提供人机交互接口, 支持工作人员对系统进行监控、调试与管理, 实现高速 WDM 系统集成的智能化、自动化, 切实解决系统集成过程中的痛点问题, 提升系统集成效率与稳定性。

3. 模型实现

针对高速无源波分复用(WDM)系统集成过程中存在的损耗波动、一致性差等痛点, 结合 LSTM 深度学习擅长处理时序数据的优势, 设计双 LSTM 模型, 采用独立建模、数据共享、任务分离架构, 分别实现系统性能预测与智能故障诊断功能, 为系统集成的智能优化提供核心算法支撑。LSTM-Reg 模型用于性能时序预测任务, LSTM-CIs 用于故障分类诊断任务, 两个模型不共享权重、不联合端到端训练, 仅共享预处理后的时序样本, 便于工程部署、模块替换与升级维护。模型设计严格遵循软件工程化思想, 从数据集构建、数据预处理、模型结构设计、训练优化及评价指标等方面, 确保模型的实用性、准确性与工程可实现性, 适配高速 WDM 系统的实际应用场景。

(一) 性能预测数据集构建

数据集是 LSTM 性能预测模型训练与验证的基础, 结合高速 WDM 系统集成的实际场景, 本文采集了工业实验现场具有时序特性的关键数据, 构建符合模型训练要求的时序样本, 确保数据的真实性、完整性与时效性, 为模型精准预测提供支撑。

数据集包括了与系统集成质量、传输性能密切相关的 5 类关键指标, 覆盖环境、器件、系统三个维度, 具体如表 1 所示。

Table 1. Key indicators of the dataset**表 1.** 数据集关键指标

序号	指标名	指标含义
1	温度	波动会直接影响硅基 AWG 芯片的波导损耗、光纤与芯片的耦合效率，是导致性能波动的核心环境因素
2	插入损耗	
3	耦合损耗	直接决定硅基 AWG 芯片及封装组件的性能，是评估系统集成质量的核心指标
4	串扰	
5	性能指标	反映系统的传输稳定性，是判断系统性能劣化的关键依据

由于 LSTM 模型本质是处理时序数据的深度学习模型，需将采集到的原始数据构造为时序样本格式，才能充分发挥模型捕捉时序依赖关系的优势。采用滑动窗口法构造时序样本，具体流程如下：首先，对采集到的 5 类指标数据按时间戳排序，形成连续的时序数据序列；其次，设定滑动窗口长度与预测步长，其中窗口长度设为 60，即利用前 60 秒的时序数据作为输入特征；预测步长设为 N ， N 可根据实际应用需求调整，本文默认 $N=5$ ，即预测未来 5 秒的性能指标变化；最后，以滑动窗口为单位，从时序数据序列中截取样本，每个样本包含输入特征矩阵与输出标签，输入特征矩阵为 60×5 的二维矩阵，60 个时间步，5 类采集指标，输出标签为 5×1 的一维向量。该一维向量是未来 5 秒的核心性能指标预测值。通过该方法，共构造训练样本 8450 个、验证样本 2820 个、测试样本 1440 个，样本比例为 6:2:1，确保模型训练、验证与测试的科学性。

采集到的原始数据中存在噪声、缺失值、异常值等问题，且不同指标的量纲差异较大，直接输入 LSTM 模型会影响模型训练效率与预测精度。因此，需对原始数据进行系统性预处理，将其转换为符合模型输入要求的标准化时序数据，具体包括标准化、平滑、去噪、时序滑窗四个步骤，确保数据质量。由于不同采集指标的量纲差异显著，会导致模型训练过程中对量纲较大的指标过度侧重，影响模型拟合效果。采用 Z-score 标准化方法对所有指标数据进行归一化处理，将数据映射到均值为 0、标准差为 1 的标准正态分布范围内，消除量纲差异。通过标准化处理，确保各类指标在模型训练中具有同等权重，提升模型训练的稳定性。

原始数据中存在因传感器误差、测试仪器波动导致的随机噪声，会干扰时序数据的变化规律，影响模型对有效信息的捕捉。采用移动平均法进行数据平滑处理，通过计算相邻 k 个时间步的平均值替换当前时间步的数据，消除随机噪声，其中 k 设为 5，兼顾数据平滑效果与时序特征保留。对于平滑后仍存在的异常值，采用 3σ 准则进行识别与处理，将超出均值 ± 3 倍标准差的数据判定为异常值，采用线性插值法替换异常值，确保时序数据的连续性与完整性。此外，还应对预处理后的标准化数据进行时序滑窗处理，确保窗口滑动的连续性，避免样本重叠过多导致的数据冗余，同时剔除滑动过程中产生的不完整样本，最终得到符合 LSTM 模型输入要求的时序样本集，为后续模型训练奠定基础。

设备故障主要包括 5 种，插入损耗变化率 R_{il} 、耦合损耗波动值 V_{cl} 、串扰峰值 P_{st} 、误码率均值 \bar{E} 和温度变化梯度 G_T ，其计算公式如下所示。这 5 个特征将作为故障诊断模型的固定收入，确保可解释、可复现。

$$R_{il} = \frac{IL(t) - IL(t-60)}{IL(t-60)} \quad (1)$$

$$V_{cl} = \max(CL(t-60:t)) - \min(CL(t-60:t)) \quad (2)$$

$$P_{st} = \max(XT(t-60:t)) \quad (3)$$

$$\bar{E} = \frac{1}{60} \sum_{i=t-60}^t E(i) \quad (4)$$

$$G_T = \frac{T(t) - T(t-60)}{60} \quad (5)$$

(二) 模型构建

基于预处理后的时序样本, 设计 LSTM 性能预测模型, 核心目标是通过学习历史时序数据的变化规律, 实现对高速 WDM 系统未来 N 步核心性能指标的精准预测, 例如插入损耗、耦合损耗、串扰、传输误码率等。模型采用分层结构, 从下至上依次为输入层、隐藏层、输出层, 各层模块化设计, 确保模型的可扩展性与可维护性, 具体结构设计如下:

1) 输入层的核心功能是接收预处理后的时序特征数据, 为模型提供训练与推理的输入信号。输入层的维度与时序样本的输入特征矩阵维度一致, 即输入维度为(None, 60, 5), 其中 None 表示批量大小, 60 为滑动窗口长度, 5 为采集指标数量, 包括温度、插入损耗、耦合损耗、串扰、传输误码率。输入层采用全连接方式将时序特征数据传入隐藏层, 确保数据传输的完整性, 同时添加 Dropout 层(dropout rate = 0.2), 防止模型训练过程中出现过拟合现象。

2) 隐藏层是 LSTM 预测模型的核心计算层, 负责捕捉时序数据中的长期依赖关系, 实现对历史数据特征的提取与学习。隐藏层采用两层 LSTM 单元堆叠结构, 第一层 LSTM 单元数量设为 128, 第二层 LSTM 单元数量设为 64, 通过两层堆叠提升模型对复杂时序特征的拟合能力。每层 LSTM 单元均包含输入门、遗忘门、输出门三大核心结构, 遗忘门采用 sigmoid 激活函数, 控制历史信息的丢弃; 输入门采用 sigmoid 激活函数与 tanh 激活函数结合, 实现当前信息的筛选与更新; 输出门采用 sigmoid 激活函数与 tanh 激活函数结合, 控制当前信息的输出。同时, 在两层 LSTM 单元之间添加 Dropout 层(dropout rate = 0.2), 进一步抑制过拟合, 提升模型的泛化能力。

3) 输出层的核心功能是将隐藏层提取的时序特征映射为未来 N 步的性能指标预测值, 输出维度与预测步长 N 及性能指标数量匹配。本文中 $N=5$, 核心预测指标包括插入损耗、耦合损耗、串扰、传输误码率, 因此输出层维度设为(None, 5, 4), 其中 None 为批量大小, 5 为预测步长, 4 为核心预测指标数量。输出层采用线性激活函数, 确保预测值的连续性与准确性, 贴合性能指标的实际变化规律, 最终输出未来 5 秒内每一秒的 4 类核心性能指标预测值。

4) 模型超参数直接影响模型的训练效果与预测精度, 采用网格搜索法对核心超参数进行寻优, 筛选出最优超参数组合。需优化的核心超参数包括: LSTM 隐藏层单元数量、滑动窗口长度、批量大小、迭代次数、Dropout 率。通过网格搜索遍历不同超参数组合, 以验证集的 MSE 作为评价指标, 并进行 5 折交叉验证。搜索范围如表 2 所示。筛选出最优超参数组合如下: LSTM 隐藏层单元数量(128, 64)、滑动窗口长度 = 60、批量大小 = 32、迭代次数 = 100、Dropout 率 = 0.2。同时, 在模型训练过程中添加早停策略, 当验证集的 MSE 连续 10 个迭代周期不再下降时, 停止模型训练, 防止模型过拟合, 确保模型泛化能力。

Table 2. Range of hyperparameter grid search
表 2. 超参数网格搜索范围

序号	指标名	搜索范围
1	滑动窗口长度	{20, 40, 60, 80}
2	LSTM 单元数	{(64, 32), (128, 64), (256, 128)}
3	BatchSize	{16, 32, 64}

续表

4	学习率	{0.0001, 0.001, 0.01}
5	Dropout	{0.1, 0.2, 0.3}
6	迭代次数	{50, 100, 150}

4. 实验结果

针对高速 WDM 系统集成与运行过程中常见的故障类型, 设计 LSTM 智能故障诊断模型, 通过学习故障状态下的时序特征, 实现对故障类型的精准识别与分类, 为故障排查与系统调试提供支撑, 降低人工诊断成本, 提升系统集成的效率与稳定性。

故障主要包括耦合偏移故障、芯片劣化故障、光纤损耗增大故障和传输误码超标故障。本文提取 5 类核心故障特征, 包括插入损耗变化率、耦合损耗波动值、串扰峰值、误码率均值、温度变化梯度, 这些特征能够有效区分正常状态与各类故障状态, 以及不同故障类型之间的差异。时序样本构造采用与性能预测模型一致的滑动窗口法, 窗口长度设为 60, 每个样本包含 60 个时间步的故障特征数据, 输出标签为故障类型编码。该编码采用独热编码方式, 正常状态编码为[1, 0, 0, 0, 0], 耦合偏移编码为[0, 1, 0, 0, 0], 芯片劣化编码为[0, 0, 1, 0, 0], 光纤损耗增大编码为[0, 0, 0, 1, 0], 传输误码超标编码为[0, 0, 0, 0, 1]。通过模拟各类故障场景与采集实际故障数据, 共构造故障训练样本 6000 个、验证样本 2000 个、测试样本 1000 个, 涵盖正常状态与 4 类故障状态, 确保模型能够学习各类故障的时序特征。

本章设计的双 LSTM 模型, 分别实现了高速 WDM 系统的性能预测与智能故障诊断功能。性能预测模型采用输入层 - 隐藏层 - 输出层的分层结构: 输入层接收 60×5 的时序特征矩阵(60 个时间步、5 类采集指标), 添加 Dropout 层(dropout rate = 0.2)防止过拟合; 隐藏层采用两层 LSTM 单元堆叠(128 个 + 64 个), 通过输入门、遗忘门、输出门捕捉时序数据长期依赖关系; 输出层采用线性激活函数, 输出未来 5 步 4 类核心性能指标的预测值。模型训练与优化过程中, 选用均方误差作为损失函数, 衡量预测值与实际值的偏差; 采用 Adam 优化器加快收敛速度, 避免梯度消失/爆炸; 通过网格搜索法优化超参数, 确定最优组合为: 滑动窗口长度 60、批量大小 32、迭代次数 100、Dropout 率 0.2, 结合早停策略, 即连续 10 个迭代周期验证集 MSE 不下降则停止训练, 进一步提升模型泛化能力。

智能故障诊断模型基于性能预测模型改进, 适配故障分类需求, 结构为输入层 - 隐藏层 - 全连接层 - 输出层: 输入层接收 60×5 的故障时序特征, 如插入损耗变化率、耦合损耗波动值等; 隐藏层采用 64 个 LSTM 单元, 捕捉故障时序特征变化规律; 全连接层(32 个 + 16 个单元)进一步提取故障特征; 输出层采用 softmax 激活函数, 输出 5 类标签的概率值, 分别表达正常状态和 4 类故障。其中 4 类核心故障定义为: 耦合偏移、芯片劣化、光纤损耗增大、传输误码超标。故障特征提取聚焦于区分不同故障的关键指标, 时序样本构造与性能预测模型保持一致, 确保数据兼容性与模型训练效率。模型评价采用准确率、精确率、召回率、F1 值四项核心指标, 全面衡量分类性能。

为验证本文设计双 LSTM 模型的优越性, 将其与传统机器学习方法, 包括 BP 神经网络、SVM、传统 RNN 等进行对比测试, 测试环境一致, 采用相同数据集, 对比结果如表 3 所示。由表可知, 本文设计的 LSTM 性能预测模型, 预测误差为 0.0028, 较 BP 神经网络(0.0083)、SVM(0.0076)、传统 RNN(0.0045)分别降低 66.27%、63.16%、37.78%, 预测精度显著提升, 能够更精准捕捉时序性能变化规律; LSTM 故障诊断模型, 准确率达到 97.3%, 精确率、召回率、F1 值均超过 96.5%, 较 BP 神经网络(准确率 91.2%)、SVM(准确率 90.5%)、传统 RNN(准确率 93.8%)分别提升 6.1%、6.8%、3.5%, 故障识别的精准度与全面性更优, 有效降低误判、漏判概率。

Table 3. Computational results of various models**表 3.** 各种模型的计算结果

模型类型	性能预测 (MSE)	性能预测误差降低率	故障诊断准确率 (%)	故障诊断准确率提升率	精确率 (%)	召回率 (%)	F1 (%)
本文模型	0.0028	-	97.3	-	96.7	96.2	96.4
BP 神经网络	0.0083	66.27%	91.2	6.1%	89.8	89.3	89.5
SVM	0.0076	63.16%	90.5	6.8%	90.2	89.7	89.9
传统 RNN	0.0045	37.78%	93.8	3.5%	93.1	92.8	92.9

为验证本文所提智能集成框架在实际工程场景中的应用效果, 在高速 WDM 无源器件封装耦合工位开展验证实验。实验以硅基 AWG 器件自动封装集成为对象, 通过 LSTM 性能预测模型实时感知状态、预判劣化趋势, 并进行参数修正, 形成“预测、决策、执行、反馈”的完整闭环。在实验过程中, 首先通过 LSTM-Reg 性能预测模型对实时采集的时序数据进行处理, 提前 5 s 实施预测, 发现当前工作状态下耦合损耗将由 0.8 dB 快速上升至 1.5 dB, 同时插入损耗同步升高, 系统即将进入性能劣化状态。为避免损耗超标导致集成良率下降, 系统依据模型输出结果, 自动生成最优参数调整策略, 并驱动六轴自动对准平台执行微调节操作, 对 X/Y 轴进行 $\pm 0.5 \mu\text{m}$ 的高精度位置补偿, 对耦合角度进行 0.03° 的精准修正, 同时将激光输出功率进行 +0.2 dBm 的预稳定处理。

参数自动调整完成后, 对系统关键性能指标进行复测与统计。耦合损耗由调整前 1.52 dB 降至 0.76 dB, 指标改善幅度达到 49.3%; 插入损耗由 1.98 dB 降至 1.13 dB, 改善幅度为 42.9%; 串扰由 -22 dB 优化至 -31 dB, 提升 9 dB; 传输误码率由 2.1×10^{-11} 优化至 8.3×10^{-14} , 达到批量生产标准要求。在工程效率方面, 单器件平均调试时间由 98 s 缩短至 42 s, 集成效率提升 57.1%。实验结果表明, 本文提出的基于 LSTM 的智能集成优化框架可提前识别系统性能劣化趋势, 并通过自动化参数调整实现快速纠偏, 显著提升高速 WDM 系统集成的稳定性、良率与工程效率, 具备实际产线落地价值。

5. 结论

本文围绕高速无源波分复用系统集成痛点, 完成了双 LSTM 模型的设计与优化, 通过合理构建时序数据集、科学预处理数据, 实现了系统性能预测与智能故障诊断两大核心功能, 经与传统机器学习方法对比验证, 模型在预测精度、故障诊断准确率等关键指标上均有显著优化, 有效解决了系统集成中损耗波动、一致性差、故障诊断低效等问题, 为高速 WDM 系统的智能化集成提供了可靠的算法支撑与工程化思路。未来将进一步优化模型结构, 引入 BiLSTM、Transformer 等更深层次的网络架构提升模型性能; 推动模型工程化部署, 落地到实际生产线, 实现系统集成的自动化、智能化升级; 同时探索多系统协同智能优化方案, 拓展模型应用场景, 助力高速光通信系统集成技术的持续发展。

基金项目

该项目由山东省重点研发计划资助, 编号: 2024TSGC0174。

参考文献

- [1] Pincemin, E. and Renais, O. (2024) Interoperable Coherent WDM Interfaces at 400G and 800G. *Optical Fiber Communication Conference (OFC) 2024*, San Diego, 24-28 March 2024, W3G.3. <https://doi.org/10.1364/ofc.2024.w3g.3>
- [2] Chen, X., Milosevic, M.M., Stankovic, S., Reynolds, S., Bucio, T.D., Li, K., et al. (2018) The Emergence of Silicon Photonics as a Flexible Technology Platform. *Proceedings of the IEEE*, **106**, 2101-2116. <https://doi.org/10.1109/jproc.2018.2854372>

- [3] 陈赞昌, 梅亮, 贺鸣文, 等. 基于 DWDM 的超 100Gbit/s 混合组网分析[J]. 光通信研究, 2024(1): 66-72.
- [4] 李良川, 周骥, 忻向军. 长途光传输系统算法和芯片的演进与挑战(特邀) [J]. 光学学报, 2025, 45(13): 215-225.
- [5] 张卓宇, 蒋林, 陈博阳, 等. 基于深度学习的光电振荡混沌系统建模及 FPGA 应用[J]. 光学学报, 2024, 44(19): 117-127.
- [6] Hu, J., Zhang, S., Cai, M., Ma, M., Li, S., Chen, H., *et al.* (2025) LSTM-Assisted Optical Fiber Interferometric Sensing: Breaking the Limitation of Free Spectral Range. *Light: Science & Applications*, **14**, Article No. 392. <https://doi.org/10.1038/s41377-025-02008-4>
- [7] 周雪松, 李锦涛, 马幼捷, 等. 时序记忆深度强化学习自抗扰微网稳压控制[J]. 电机与控制学报, 2025, 29(10): 138-147, 158.
- [8] Karanov, B., Chagnon, M., Thouin, F., Eriksson, T.A., Bulow, H., Lavery, D., *et al.* (2018) End-to-End Deep Learning of Optical Fiber Communications. *Journal of Lightwave Technology*, **36**, 4843-4855. <https://doi.org/10.1109/jlt.2018.2865109>