



基于深度迁移学习的风电机组齿轮箱 故障诊断方法研究

Research on wind turbine gearbox fault diagnosis with deep
transfer learning method

答辩人：王欣

专业：机械工程

研究方向：机械故障诊断

导师：刘文艺 副教授



目录



1.研究背景



2.单齿故障分类模式识别




3.行星轮系齿轮故障识别



4.滚动轴承迁移故障诊断方法



5.结论与展望



第一部分

研究背景



1. 研究背景

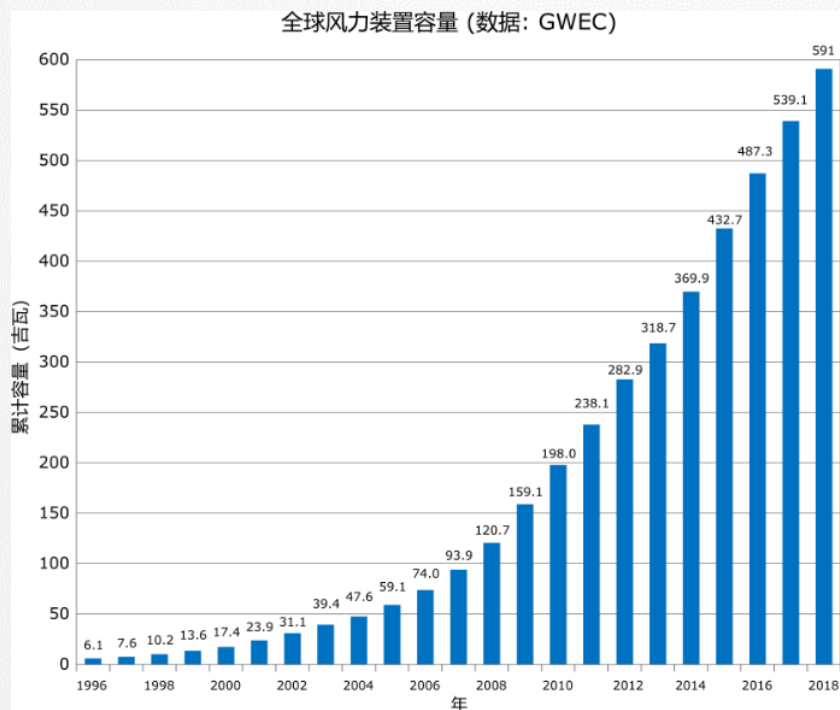


图1-1 从1996年至2018年全球风电机组
装机容量的变化




图1-2 陆地风电机组和离岸风电机组的
装机容量占比

风电产业的当前与远期发展规模

1.研究背景



江苏师范大学
JIANGSU NORMAL UNIVERSITY




图1-3 风电机组基本结构

整机结构



图1-4 增速齿轮系与行星轮系组成的结构

传动系统




图1-5 滚动轴承的基本结构

基本零部件



1. 研究背景

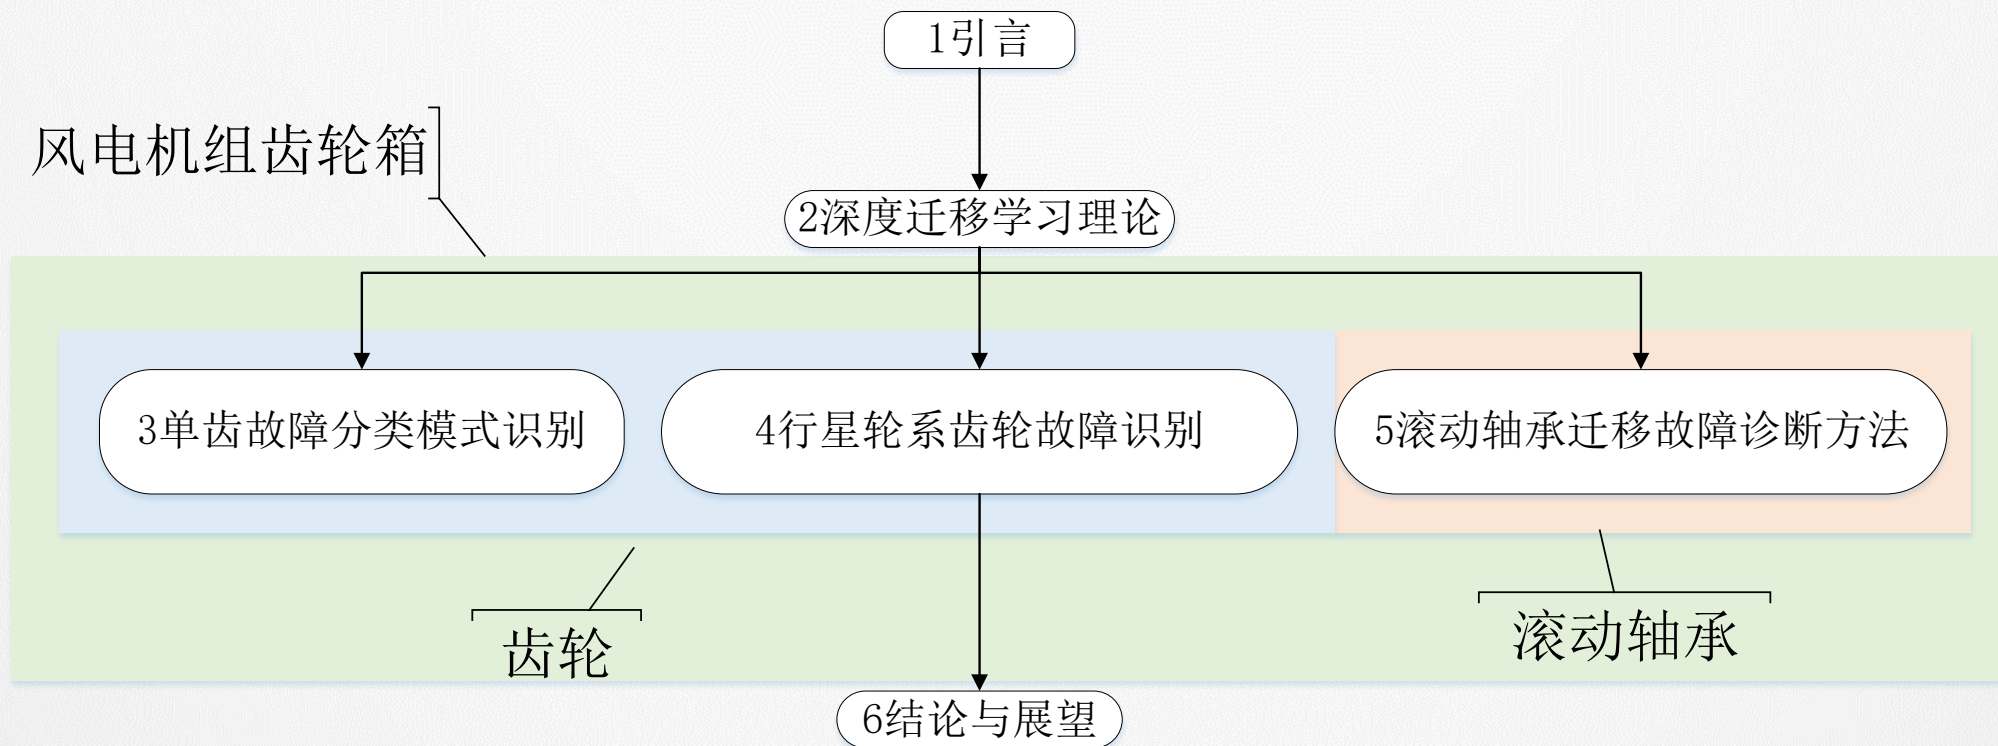


图1-6 章节内容的结构与层次关系



1. 研究背景



参考文献

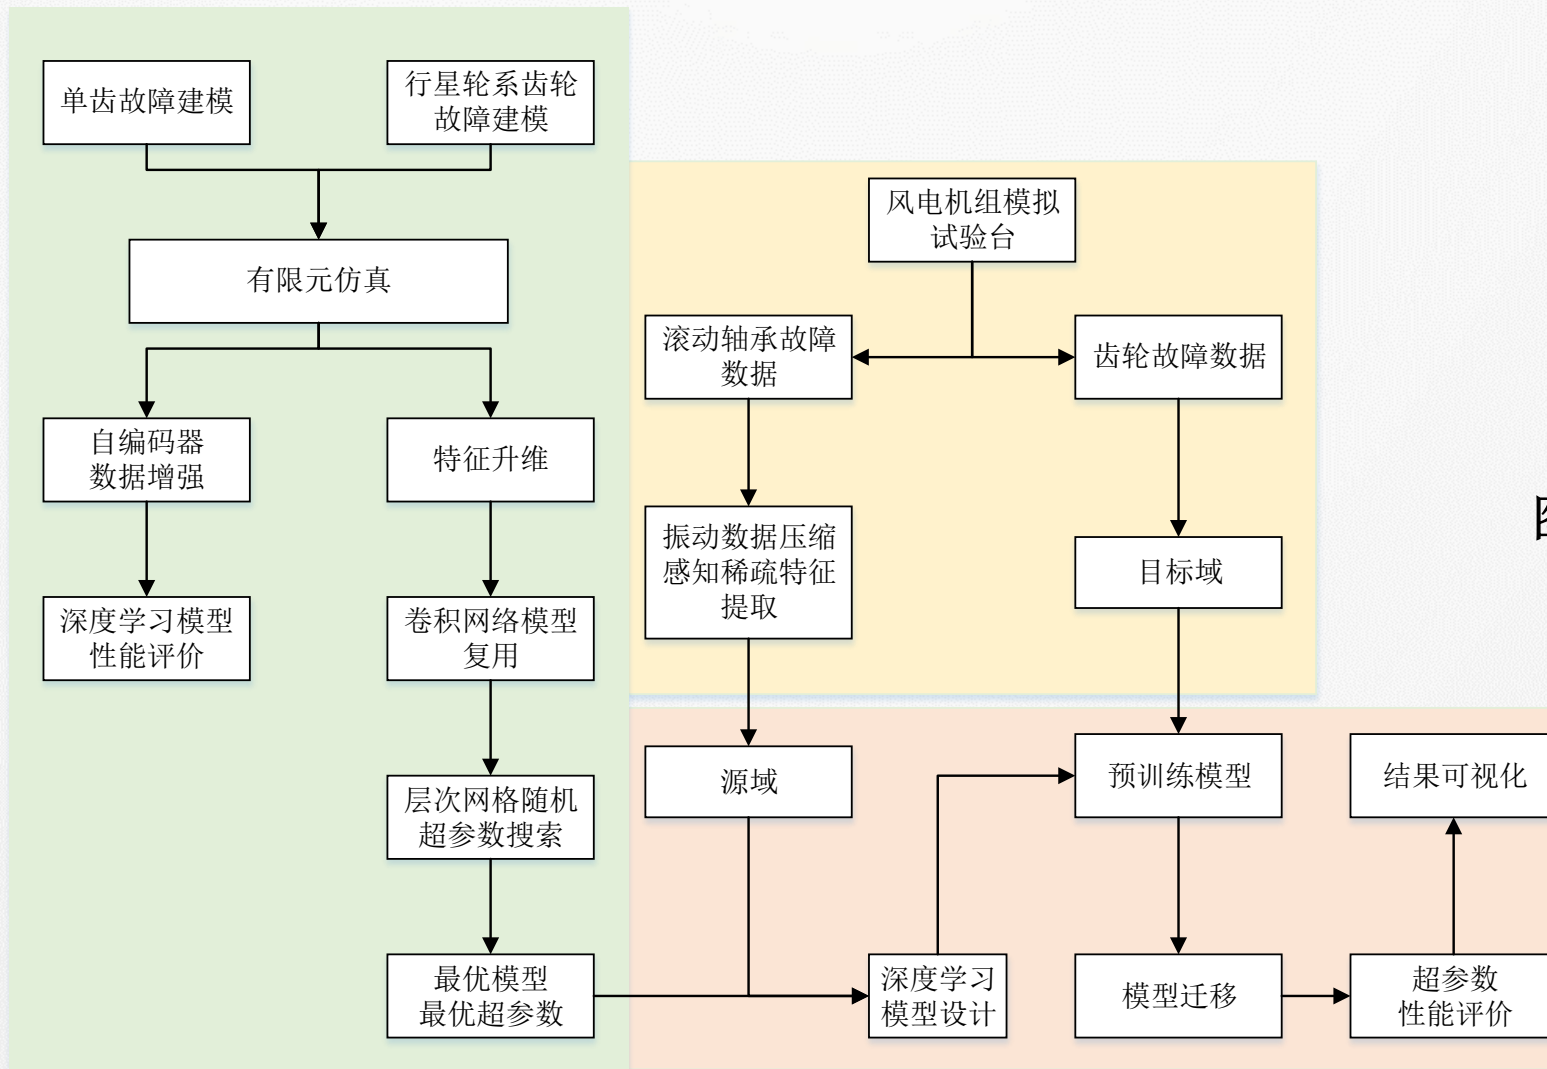



图1-7 本文技术路线

主要技术路线示意图



第二部分

2.单齿故障分类模式识别





2.单齿故障分类模式识别

研究结构、几何建模、模型尺寸



江苏师范大学
JIANGSU NORMAL UNIVERSITY

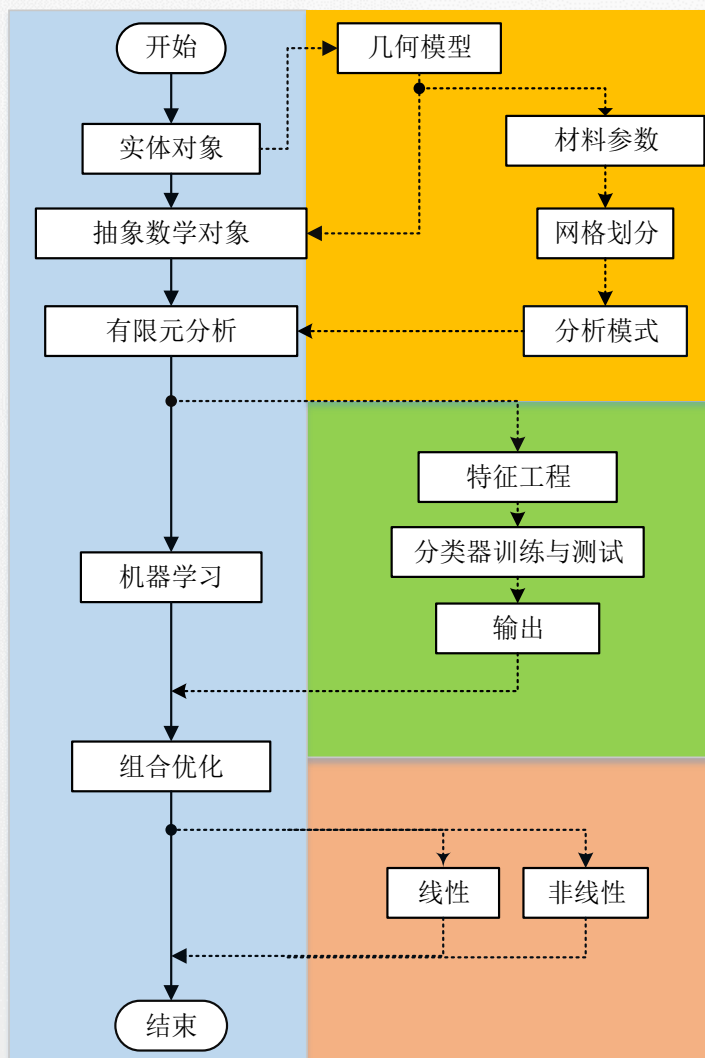


图2-1 研究结构的流程图




图2-2 (a) 单齿二维平面草图 (b) 单齿模型建模

表 2-1. 二维单齿平面几何尺寸

线段	长度
AB	2.2m
BC	1.5m
CD	0.9m
EF	0.4m

m: 齿轮的模数



2.单齿故障分类模式识别

模型设计、材料参数、有限元流程、边界条件



江苏师范大学
JIANGSU NORMAL UNIVERSITY




图2-3 四种类型的齿轮故障:

(a)点蚀 (b)尖端断裂 (c)裂纹(d)磨损

表 2-2. 普通碳钢相关材料参数

材料特征	数值	单位
弹性模量	2.2e+11	N/m ²
泊松比	0.28	/
密度	7800	kg/m ³



图2-4 模态分析的流程




图2-5 (a)网格划分 (b)&(c) 面约束与四个边线约束



2.单齿故障分类模式识别




图2-6 模态分析获得的前十阶频率

表 2-3. 总应变数据去除边界条件和零位移格点

	原始数据	预处理数据
完整单齿	26744×10	25000×10
裂纹	27811×10	25000×10
点蚀	28039×10	25000×10
尖端断裂	29444×10	25000×10
磨损	26744×10	25000×10




图2-7 谐波响应外部均匀载荷的位置

表 2-4. 谐波响应总应变数据去除边界条件和零位移格点

	原始数据	预处理数据
完整单齿	26660×30	25000×20
裂纹	27811×30	25000×20
点蚀	28039×30	25000×20
尖端断裂	29444×30	25000×20
磨损	26744×30	25000×20



2.单齿故障分类模式识别

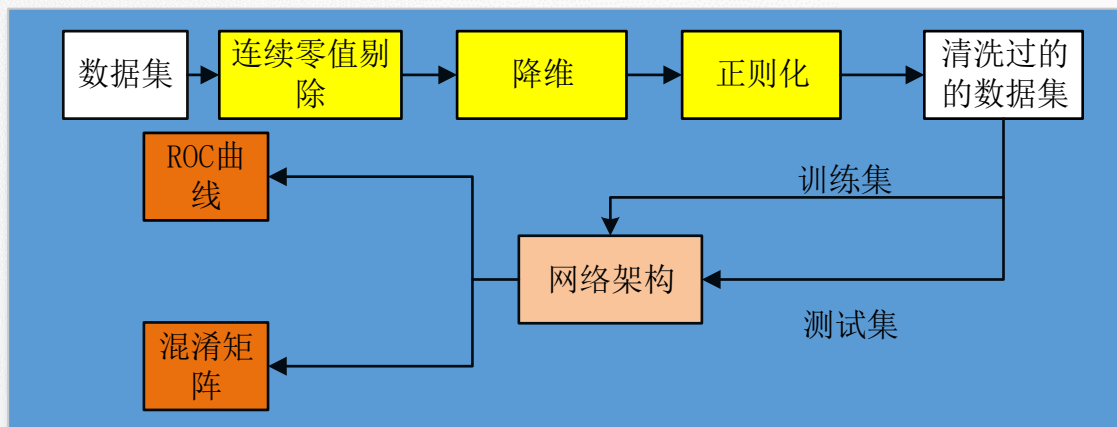
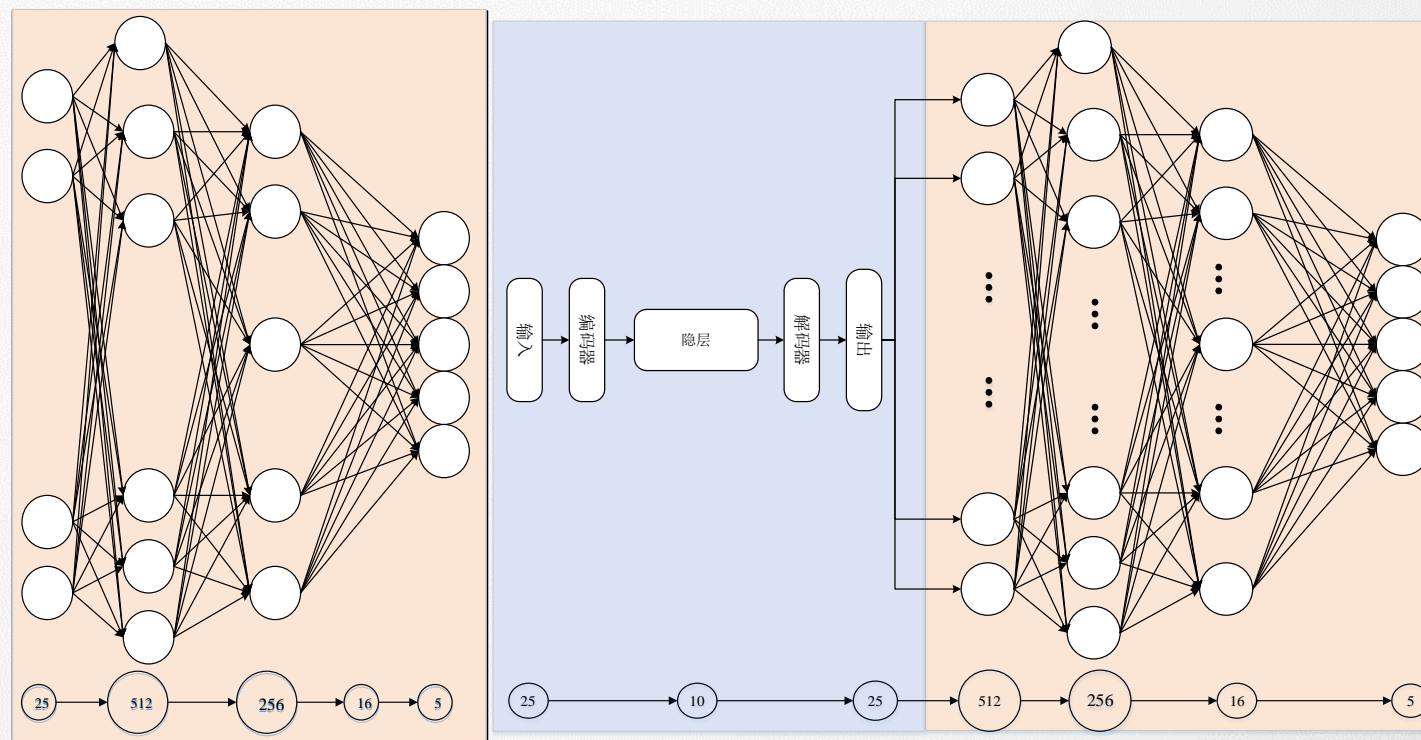


图2-8 数据处理过程与深度神经网络分类器的设计

图2-9 论文中设计的结构:

(a) 全连接网络 (b) 基于自编码器的二次训练网络





2.单齿故障分类模式识别



表 2-5. 两种数据集和网络结构下的平均准确率、迭代次数与所需时间

Table												
DNN_part_a							DNN_part_b					
	Train	Valid	Test	Average	Epoch	T	Train	Valid	Test	Average	Epoch	T
1	0.798	0.775	0.781	0.792	151	1055.052	0.660	0.666	0.652	0.660	383	2022.371
2	0.793	0.784	0.781	0.792	163	886.821	0.661	0.656	0.666	0.661	419	1909.342
3	0.799	0.775	0.787	0.794	163	893.238	0.737	0.730	0.742	0.736	882	4926.478
4	0.805	0.787	0.777	0.798	200	1103.801	0.627	0.633	0.635	0.629	412	2205.636
5	0.800	0.779	0.784	0.794	186	998.917	0.669	0.680	0.671	0.671	460	2042.183
6	0.801	0.773	0.785	0.795	144	782.685	0.663	0.656	0.666	0.662	394	1861.258
7	0.802	0.780	0.785	0.796	161	876.938	0.782	0.781	0.784	0.782	444	2354.272
8	0.801	0.775	0.776	0.794	143	783.963	0.741	0.736	0.736	0.739	481	2595.919
9	0.802	0.782	0.775	0.795	190	1053.824	0.563	0.554	0.576	0.564	474	3638.746
10	0.798	0.781	0.770	0.791	136	1065.482	0.546	0.539	0.533	0.543	200	1368.790
Average	0.800	0.779	0.780	0.794	164	950.072	0.665	0.663	0.666	0.665	455	2492.499
MAX	0.805	0.787	0.787	0.798	200	1103.801	0.782	0.781	0.784	0.782	882	4926.478
MIN	0.793	0.773	0.770	0.791	136	782.685	0.546	0.539	0.533	0.543	200	1368.790
encode_DNN_a							encode_DNN_b					
	Train	Valid	Test	Average	Epoch	T	Train	Valid	Test	Average	Epoch	T
1	0.990	0.989	0.990	0.990	395	579.018	0.998	0.999	0.998	0.998	219	1053.225
2	0.999	0.998	0.998	0.999	393	545.244	0.996	0.997	0.995	0.996	162	1249.516
3	0.998	0.996	0.997	0.997	311	338.093	0.995	0.994	0.994	0.995	103	760.655
4	0.998	0.998	0.998	0.998	260	412.248	0.993	0.995	0.994	0.994	105	753.338
5	0.997	0.996	0.998	0.997	276	363.730	0.997	0.997	0.997	0.997	116	832.044
6	0.999	0.999	0.999	0.999	603	676.354	0.997	0.996	0.997	0.997	132	935.026
7	0.998	0.997	0.999	0.998	287	383.248	0.991	0.990	0.990	0.992	94	687.211
8	0.998	0.998	0.997	0.998	380	458.975	0.993	0.992	0.994	0.993	94	687.598
9	0.995	0.993	0.995	0.995	355	435.164	0.993	0.993	0.993	0.993	106	761.219
10	0.998	0.999	0.997	0.998	381	464.765	0.994	0.993	0.995	0.994	113	836.406
Average	0.997	0.996	0.997	0.997	364	465.684	0.995	0.995	0.995	0.995	124	855.124
MAX	0.999	0.999	0.999	0.999	603	676.354	0.998	0.999	0.998	0.998	219	1249.516
MIN	0.990	0.989	0.990	0.990	260	338.093	0.991	0.990	0.990	0.992	94	682.598

十次深度神经网络的对比数值实验



2.单齿故障分类模式识别

优化目标函数的构建



江苏师范大学
JIANGSU NORMAL UNIVERSITY

准确率、训练时间和训练速度(Accuracy, Epoch Time, Training Speed)

$$\begin{pmatrix} Acc_1 & T_1 & V_1 \\ Acc_2 & T_2 & V_2 \\ Acc_3 & T_3 & V_3 \\ Acc_4 & T_4 & V_4 \end{pmatrix}_{4 \times 4} * \begin{pmatrix} W_{11} & W_{12} & W_{13} & W_{14} \\ W_{21} & W_{22} & W_{23} & W_{24} \\ W_{31} & W_{32} & W_{33} & W_{34} \end{pmatrix}_{3 \times 4} = \begin{pmatrix} Obj_1 \\ Obj_2 \\ Obj_3 \\ Obj_4 \end{pmatrix}_{4 \times 1} * \begin{pmatrix} W_1 & W_2 & W_3 & W_4 \end{pmatrix}_{1 \times 4} = \sum_{i=1}^4 W_i \cdot Obj_i$$

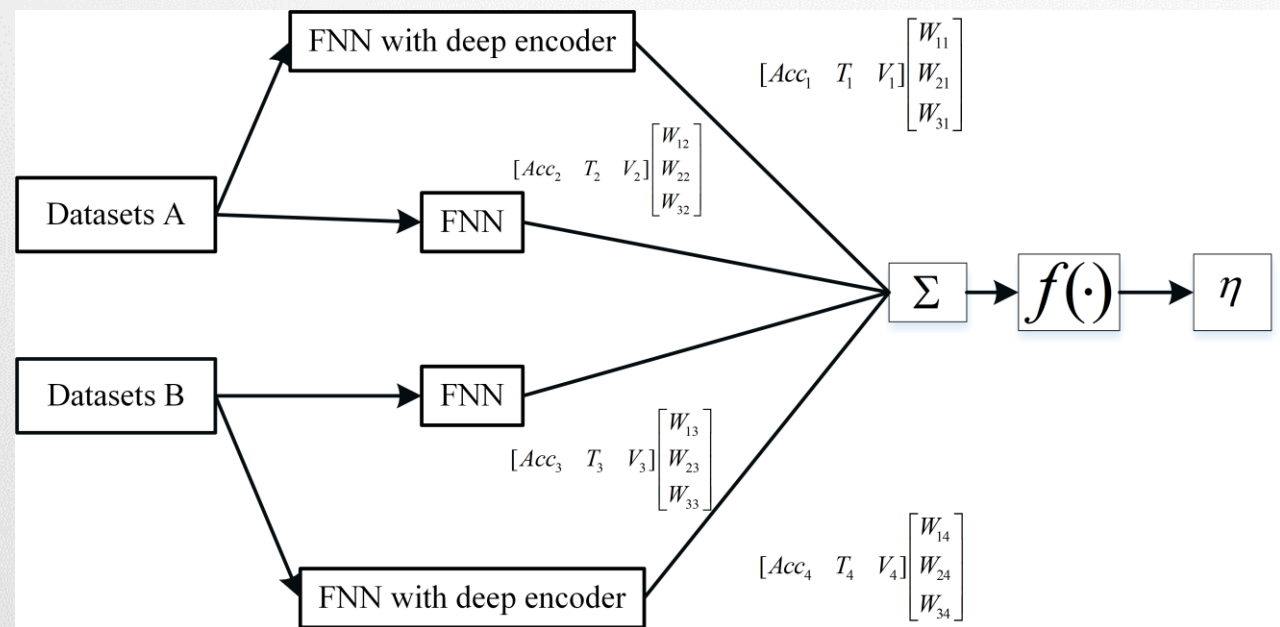


图3-10 分别使用FNN和NN based on Deep Auto-encoder 进行综合性能优化



2.单齿故障分类模式识别

代价函数、约束条件



江苏师范大学
JIANGSU NORMAL UNIVERSITY

$$\min_{W_{ij}} \eta = \min f(W_{i1}, W_{i2}, W_{i3}, W_{i4}) = \min \frac{1}{1 + e^{-\sum_{i=1}^4 W_i \cdot Obj_i}}$$

$$s.t. \sum_{i=1}^3 W_{in} = 1, n = 1, 2, 3, 4$$

$$W_{ij} \geq 0$$

表 3-6. 进行100至10000次神经网络的组合线性优化得到最小性能，最大性能和中位性能

重复实验得到神经网络的统计性能

N	最小值	最大值	中位数
100	0.5709	0.9303	0.7532
200	0.5551	0.9483	0.7443
500	0.5551	0.9205	0.7353
1000	0.5377	0.9443	0.7450
2000	0.5377	0.9393	0.7395
5000	0.5377	0.9502	0.7388
10000	0.5377	0.9443	0.7386



2.单齿故障分类模式识别

非线性目标函数构建



江苏师范大学
JIANGSU NORMAL UNIVERSITY

$$\left(\alpha \begin{pmatrix} Acc_1 \\ Acc_2 \\ Acc_3 \\ Acc_4 \end{pmatrix} \quad \beta \begin{pmatrix} T_1 \\ T_2 \\ T_3 \\ T_4 \end{pmatrix} \quad \frac{1}{\beta} \begin{pmatrix} V_1 \\ V_2 \\ V_3 \\ V_4 \end{pmatrix} \right) = \begin{pmatrix} \alpha Acc_1 & \beta T_1 & \frac{1}{\beta} V_1 \\ \alpha Acc_2 & \beta T_2 & \frac{1}{\beta} V_2 \\ \alpha Acc_3 & \beta T_3 & \frac{1}{\beta} V_3 \\ \alpha Acc_4 & \beta T_4 & \frac{1}{\beta} V_4 \end{pmatrix}$$

表 3-7. 进行100至10000次神经网络的组合非线性优化
得到最小性能, 最大性能和中位性能


N	最小值	最大值	中位数
100	0.5398	0.9127	0.7628
200	0.5514	0.9219	0.7544
500	0.5377	0.9339	0.7509
1000	0.5621	0.9483	0.7552
2000	0.5394	0.9339	0.7544
5000	0.5377	0.9483	0.7530
10000	0.5377	0.9483	0.7540

$$\min_{W_{ij}, \alpha, \beta} = \min \frac{1}{1 + e^{-\sum_{i=1}^4 (\alpha W_{1i} Acc_i + \beta W_{2i} T_i + \frac{1}{\beta} W_{3i} V_i)}}$$

$$s.t. \alpha W_{1n} + \beta W_{2n} + \frac{1}{\beta} W_{3n} = 1, n = 1, 2, 3, 4$$

$$\alpha + \beta = 1$$

$$\alpha, \beta, W_{ij} \geq 0$$




第三部分

行星轮系齿轮故障识别





3.行星轮系齿轮故障识别



(a) 太阳-行星轮传动系统




表 3-1. 论文中太阳-行星轮系传动系统参数

	太阳轮	行星轮	齿圈
齿数	38	28	94
模数	5mm		
压力角	20°		
齿宽	30mm		

表 3-2. 40CrMnMo材料参数

特征	数值	单位
弹性模量	2.05e+11	N/m ²
泊松比	0.28	/
密度	7800	kg/m ³

图3-1 (a)太阳-行星轮传动系统 (b),(c)和(d) 太阳轮、行星轮与齿圈



3.行星轮系齿轮故障识别

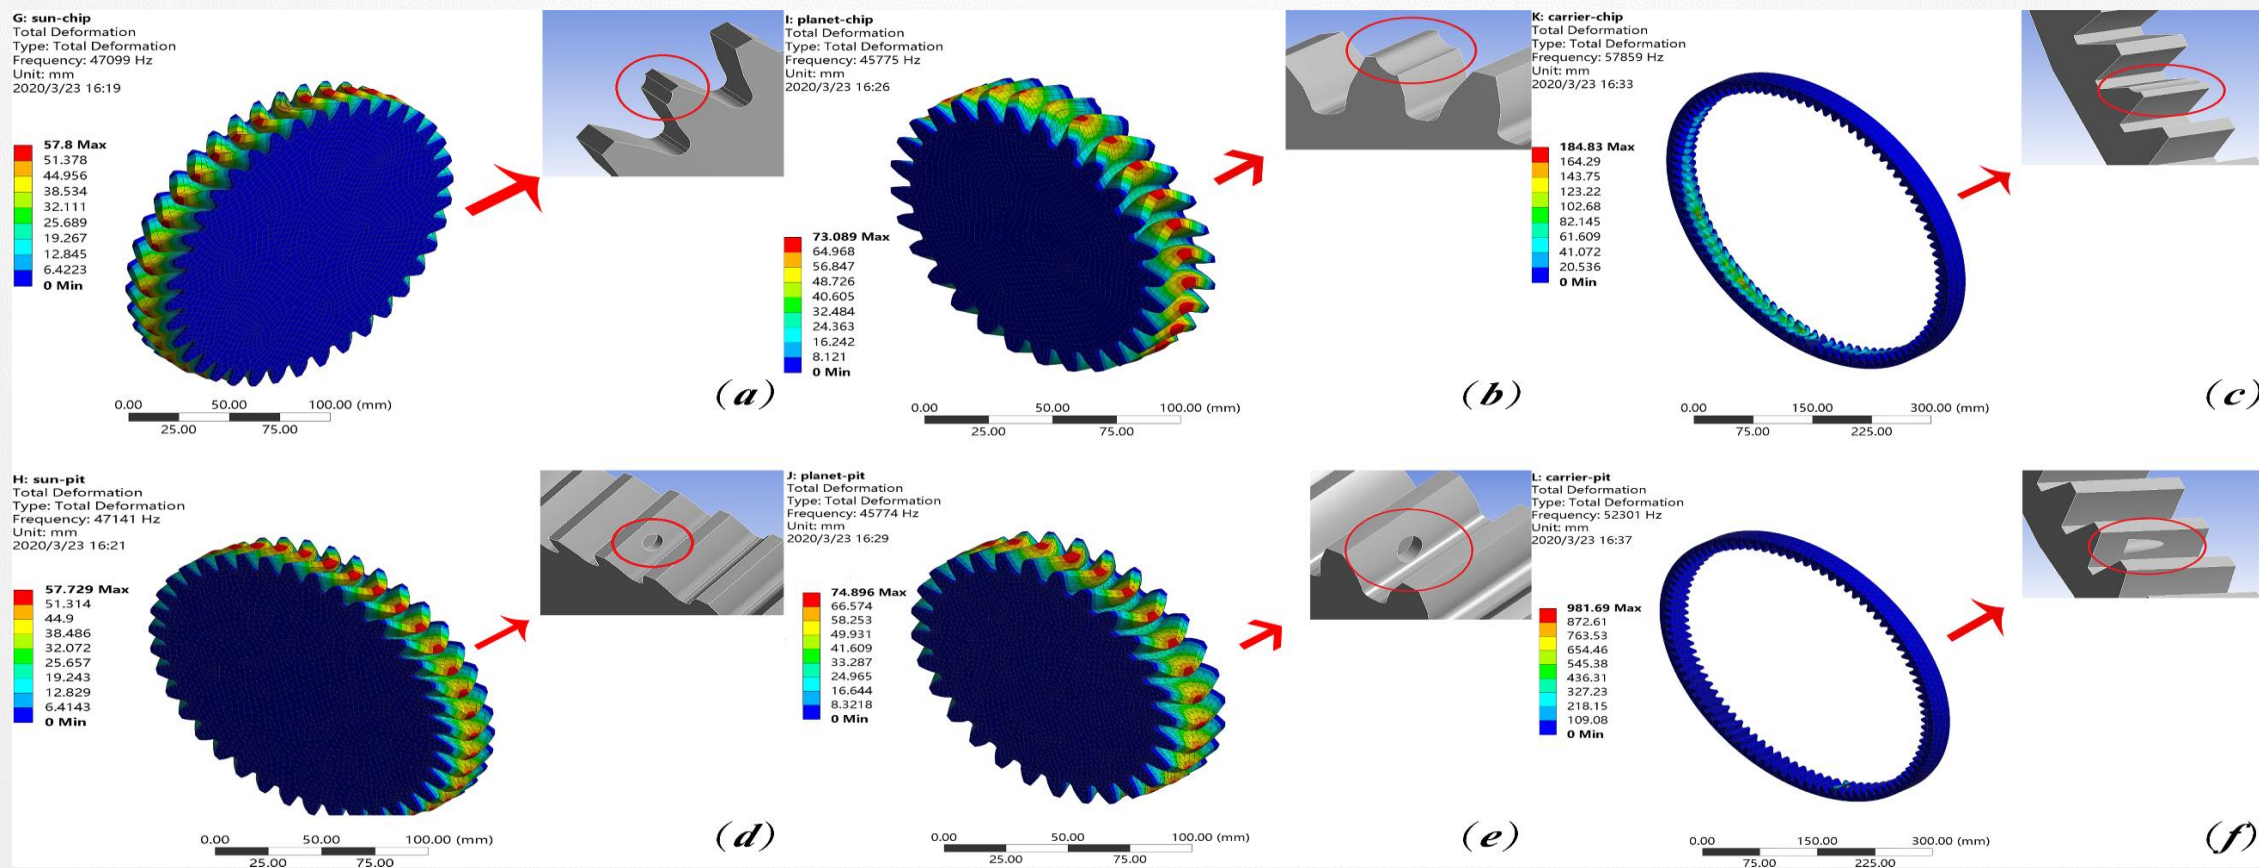


图3-2 (a),(b)与(c)太阳轮、行星轮与齿圈破损 (d),(e)与(f)太阳轮、行星轮与齿圈点蚀



3. 行星轮系齿轮故障识别



标准化处理

$$\bar{x}_i = \frac{(x_i - \max(x) + x_i - \min(x))}{\max(x) - \min(x)}$$

升维映射

$$x \in R^1 \xrightarrow{T_x} X \in R^2$$

反余弦化（弧度与半径）

$$\begin{cases} \phi = \arccos(\bar{x}_i), -1 \leq \bar{x}_i \leq 1, \bar{x}_i \in \bar{x} \\ r = \frac{i}{N}, i \in N \end{cases}$$

特征图构建

$$XS = [\cos(\phi_i + \phi_j)] = \bar{x}_i^T \cdot \bar{x}_j - \sqrt{I - \bar{x}_i^2}^T \cdot \sqrt{I - \bar{x}_j^2}$$

$$XD = [\cos(\phi_i + \phi_j)] = \sqrt{I - \bar{x}_i^2}^T \cdot \bar{x}_j - \sqrt{I - \bar{x}_j^2} \cdot \bar{x}_i^T$$



3.行星轮系齿轮故障识别

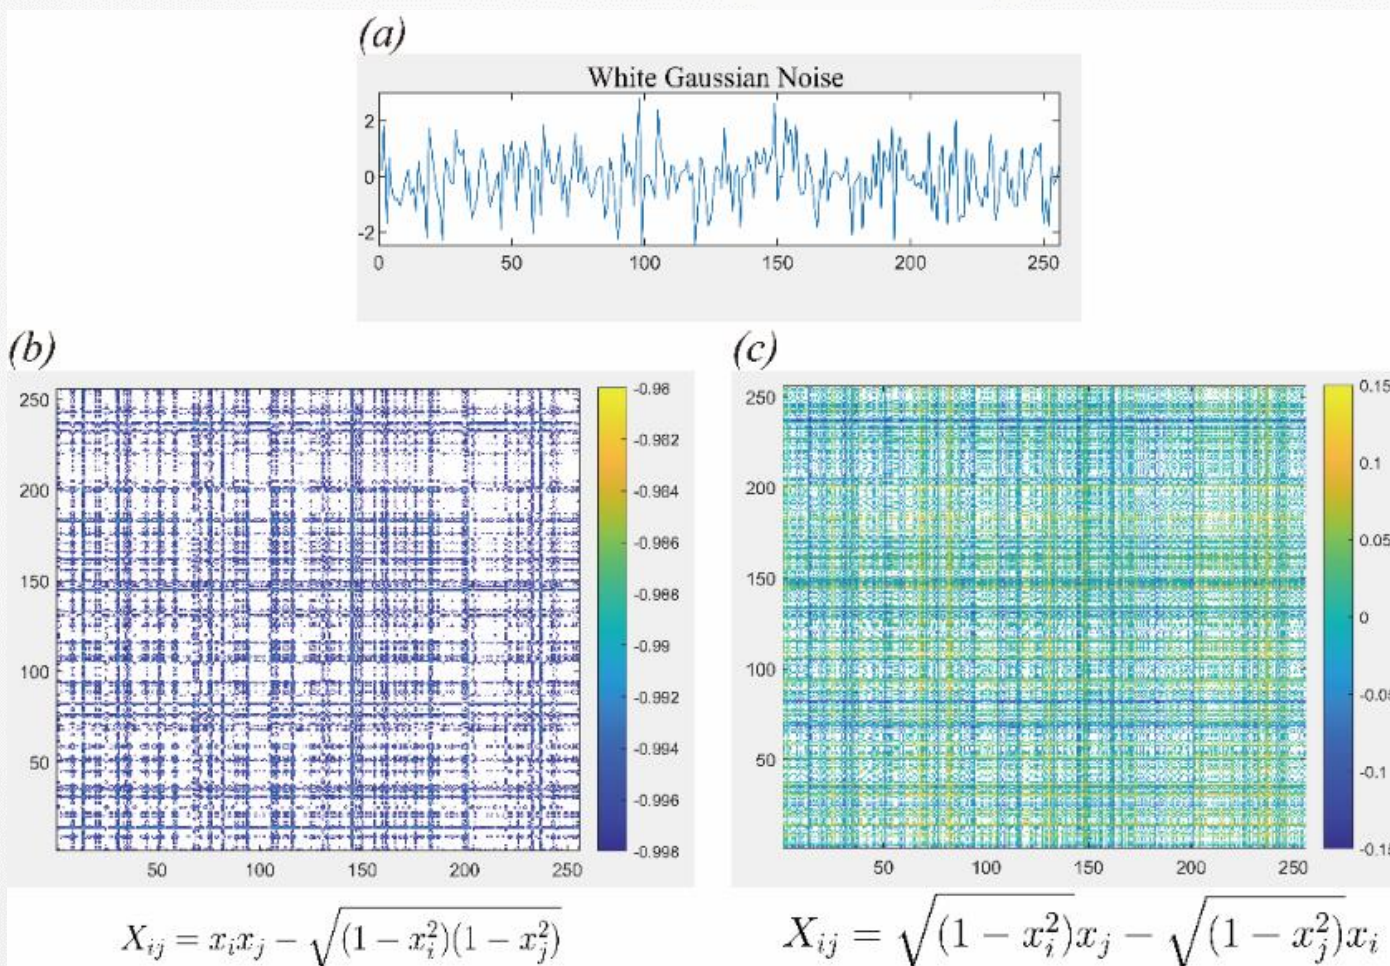
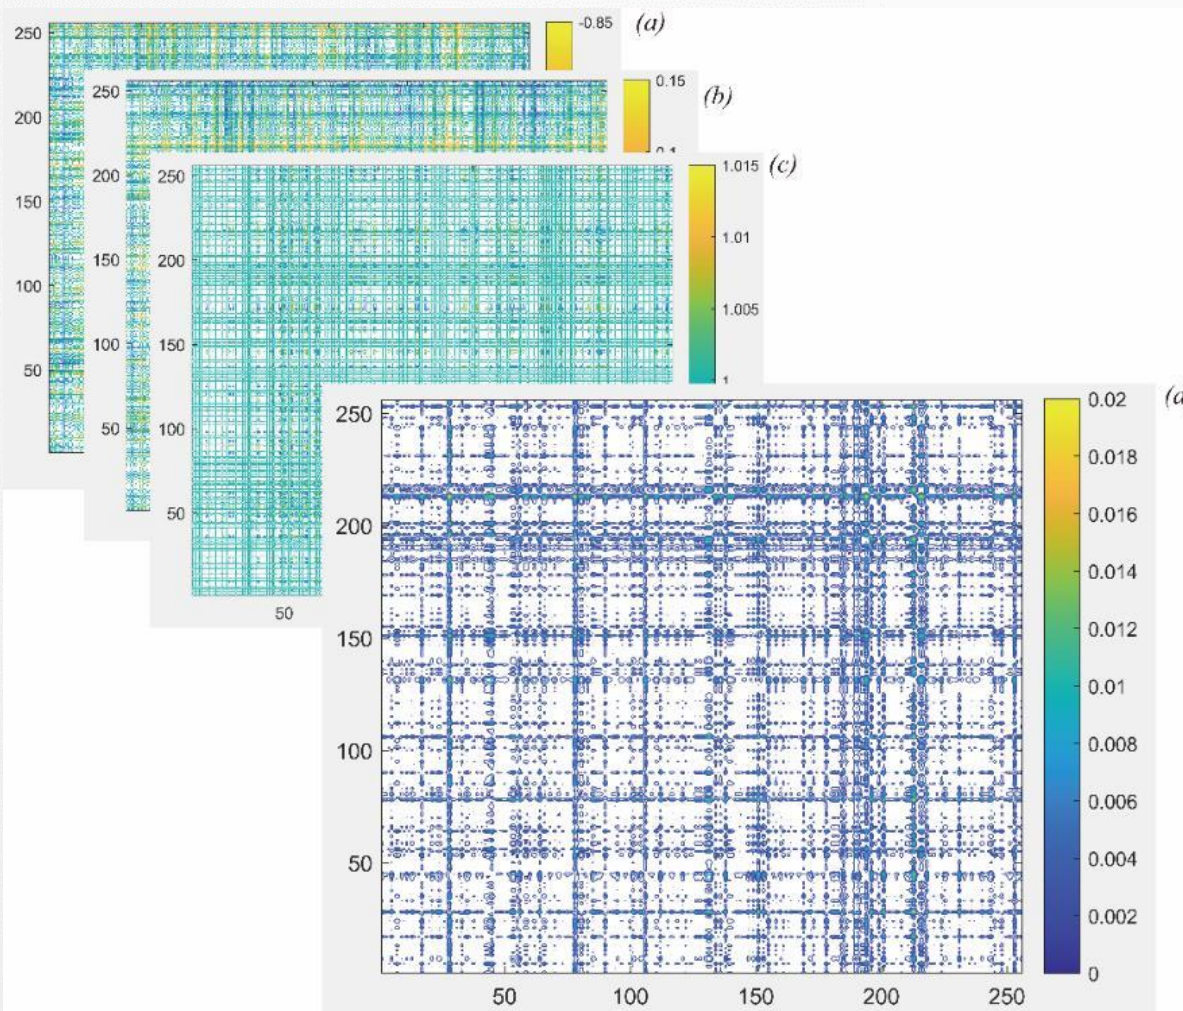


图3-3 (a) 512点的白噪声序列 (b)与(c) XS和XD的二维矩阵图



3.行星轮系齿轮故障识别



$$channel_a = XS + XD$$

$$channel_b = XS \times XD$$

$$channel_c = \sqrt{XS^2 + XD^2}$$

图3-4 (a),(b)和(c)表示三个不同通道的矩阵

图 (d)表示三个通道和的矩阵图

$$channel = (XS + XD) + (XS \times XD) + (\sqrt{XS^2 + XD^2})$$



3.行星轮系齿轮故障识别

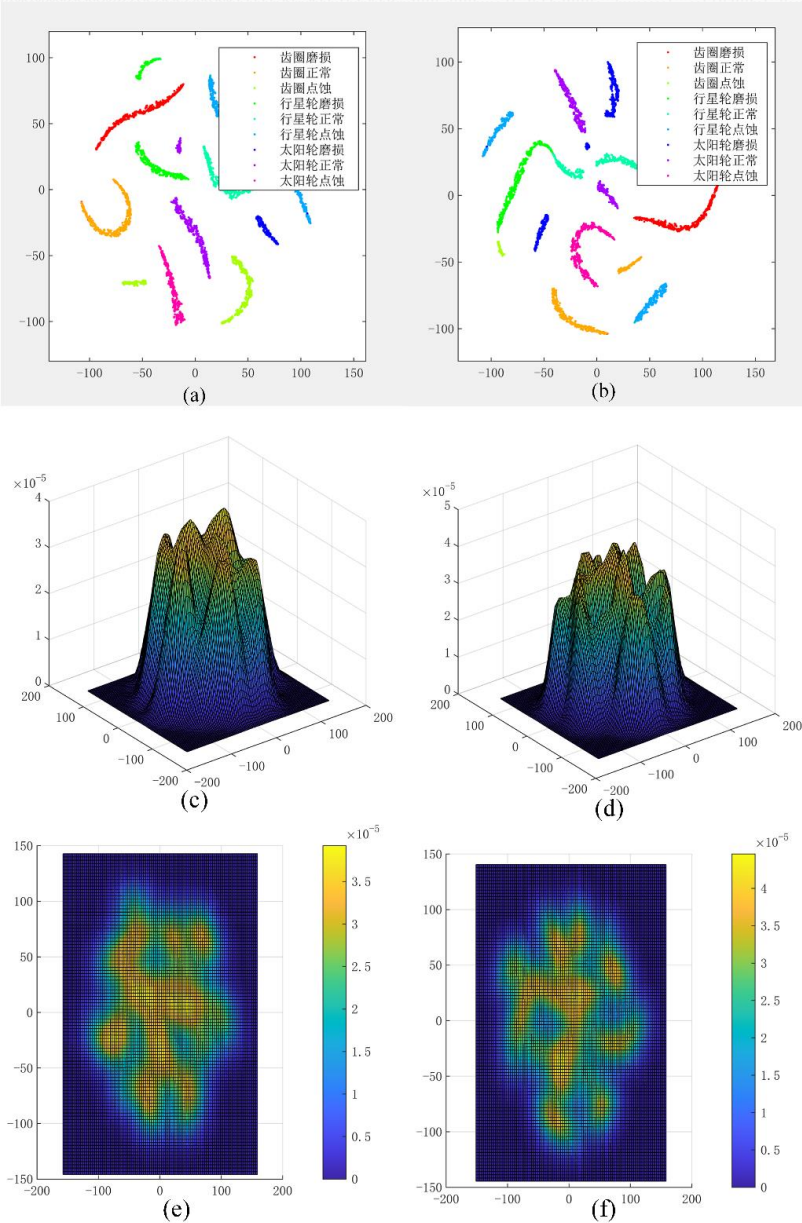


图3-5 (a)和(b)表达了T-SNE方法在单通道和三通道数据上的应用结果，并且提取前两个主成分进行了展示
(c),(d),(e)和(f)使用了无参数估计中的核密度数据估计方法分别得到其样本密度分布曲线



3.行星轮系齿轮故障识别




图3-6 研究中使用的5层LeNet5模型





图3-7 研究中使用的AlexNet模型

Stack
Frozen
Layer



Variable
parameters

图3-8 堆栈冻结方法，可训练参数随着冻结层数增加而减少



3.行星轮系齿轮故障识别




图3-9 神经网络训练过程中的超参数网格搜索与随机搜索方法

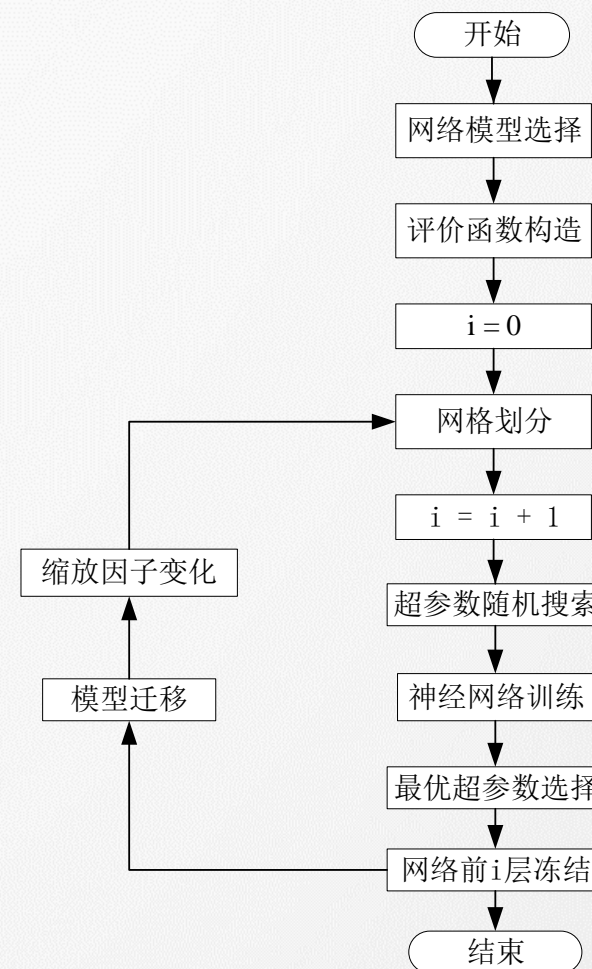


图3-10 层次网格超参数搜索算法流程图



3.行星轮系齿轮故障识别



Batch = [16, 32, 64, 128, 256, 512]
Epoch = [1000, 2000, 3000, 4000, 5000, 6000, 7000]
Learning Rate = [0.1, 0.01, 0.03, 0.05, 0.001, 0.003, 0.005, 0.0001, 0.003, 0.0005]

Batch = [12, 24, 48, 96, 192, 384]
Epoch = [1000, 1500, 2000, 2500, 3000]
Learning Rate = [0.00025, 0.0005, 0.00075, 0.001, 0.0015]

Batch = [9, 18, 36, 72, 144, 288]
Epoch = [1250, 1500, 1750, 2000, 2250, 2500]
Learning Rate = [0.00025, 0.000375, 0.0005, 0.000625, 0.0008, 0.000925]

图3-11 三个阶段搜索空间的网格划分

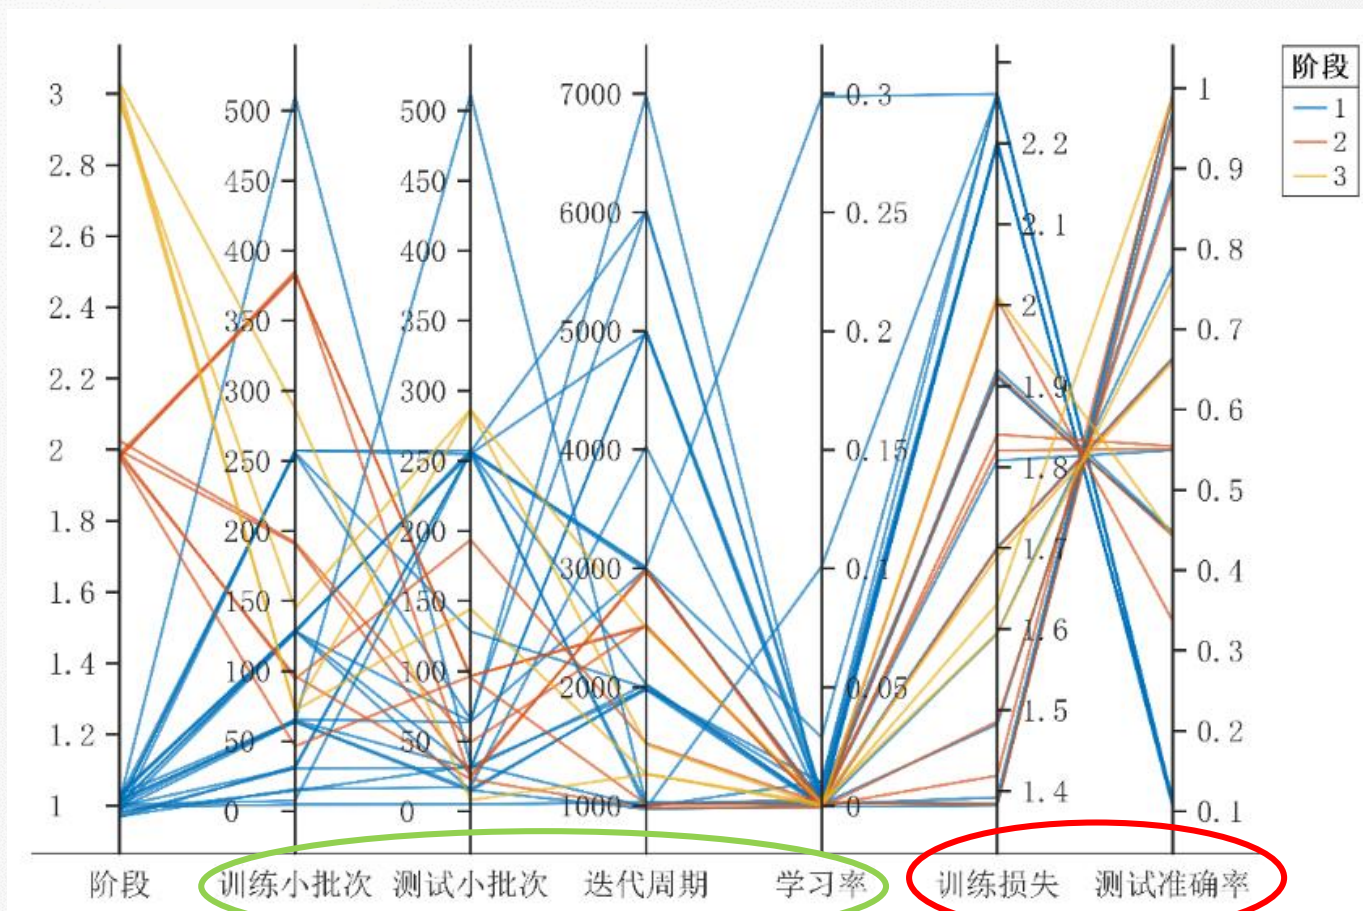


图3-12 总计35次的超参数搜索过程，

平行线图表示了超参数配置与结果的关系



3.行星轮系齿轮故障识别




图3-13 七种不同的优化器的训练过程和测试过程的可视化





图3-14 七种优化算法的训练结果与测试结果的损失与准确率示意图



第四部分

滚动轴承迁移故障诊断方法





4. 滚动轴承迁移故障诊断方法



$x = \phi s$ $\phi \in R^{n \times n}$	$y = Cx$ $C \in R^{p \times n}$
傅里叶变换 小波变换	$y = C\phi s = \theta s$ $\hat{s} = \arg \min_s \ s\ _0$ $s.t. \quad y = \theta s$
测度矩阵是方的	测度矩阵是矩形
不同域之间无损转化	不同域进行稀疏化构造



4.滚动轴承迁移故障诊断方法

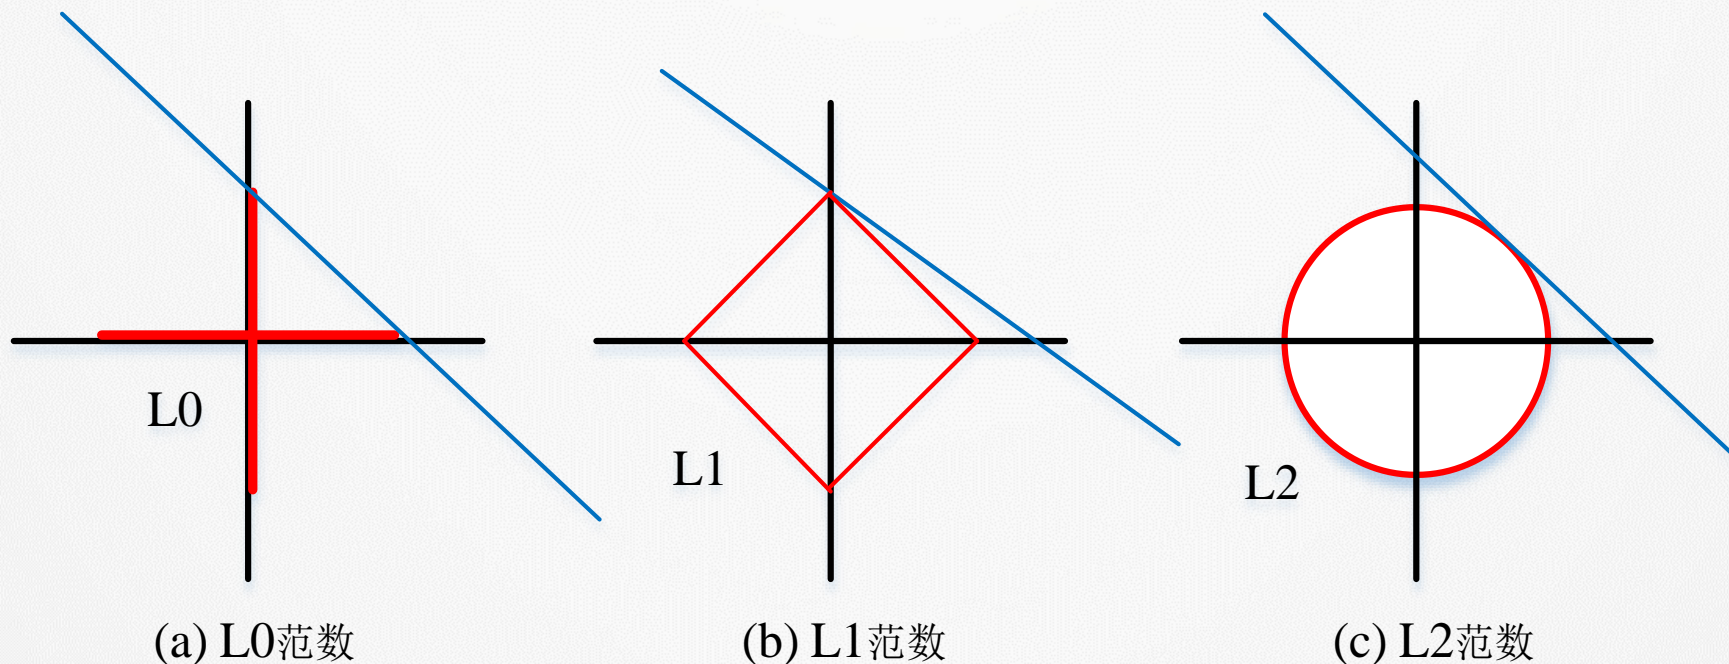


图4-1 L0~L2范数的二维平面解析示意图

$$\hat{s} = \arg \min_s (\lambda \|s\|_1 + (1-\lambda) \|s\|_2)$$

$$s.t. \quad y = \theta s$$

L1与L2按照一定的比例



4.滚动轴承迁移故障诊断方法



图 4-2 风力发电机组实验台



图 4-3 振动信号的采集

实验数据的来源是JSNU-WT-1型风电机组故障模拟实验台，该实验台利用对传动件进行电火花加工来模拟齿轮和轴承等多种故障形式。实验台的主要组件包括：控制柜、调速电机、行星齿轮箱、同步带、风力发电机等。在实验中，INV3062T0型信号采集系统用于收集振动信号。使用4个INV9822型加速度传感器收集振动信号，并使用磁性底座将传感器放置在行星齿轮箱的壳体上，振动信号由数据记录仪以25.6kHz的采样频率获取。



4.滚动轴承迁移故障诊断方法

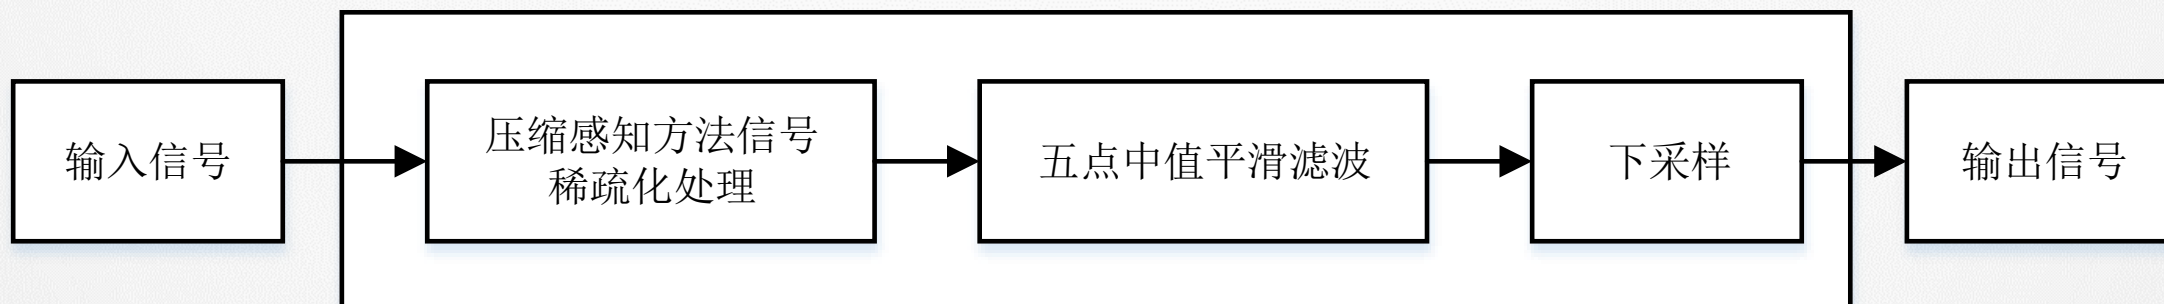


图4-4 L0~L2滚动轴承信号的信号处理设计流程

下采样的采样率和压缩感知进行处理的稀疏信号的放大倍数相同



4.滚动轴承迁移故障诊断方法

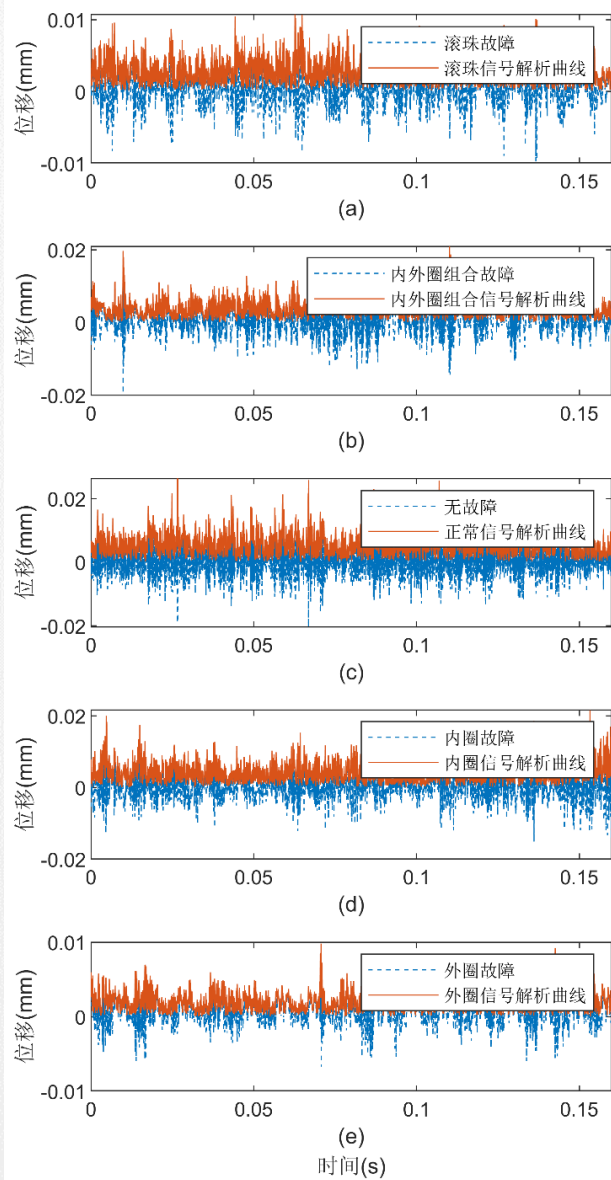


图4-5 五类信号的时域与其解析信号的时域表达



4.滚动轴承迁移故障诊断方法

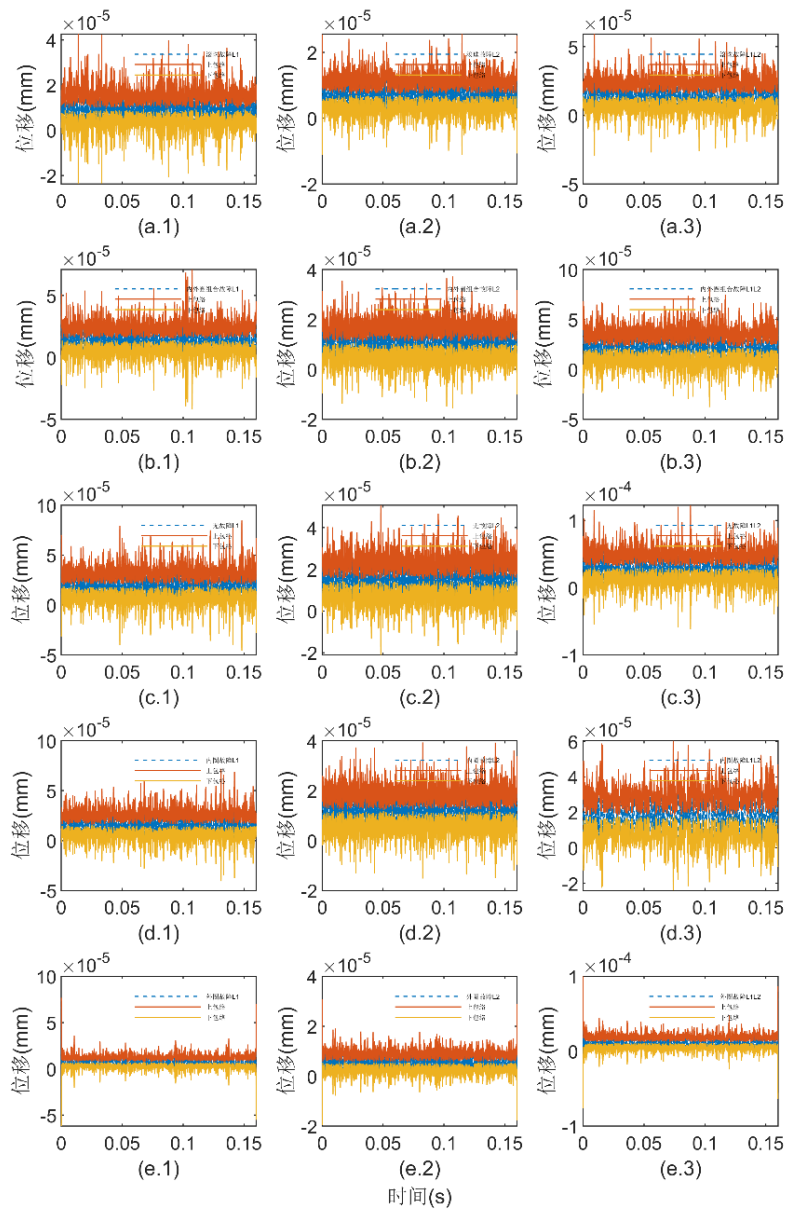


图4-6 L0~L2滚动轴承信号的上包络和下包络曲线



4.滚动轴承迁移故障诊断方法

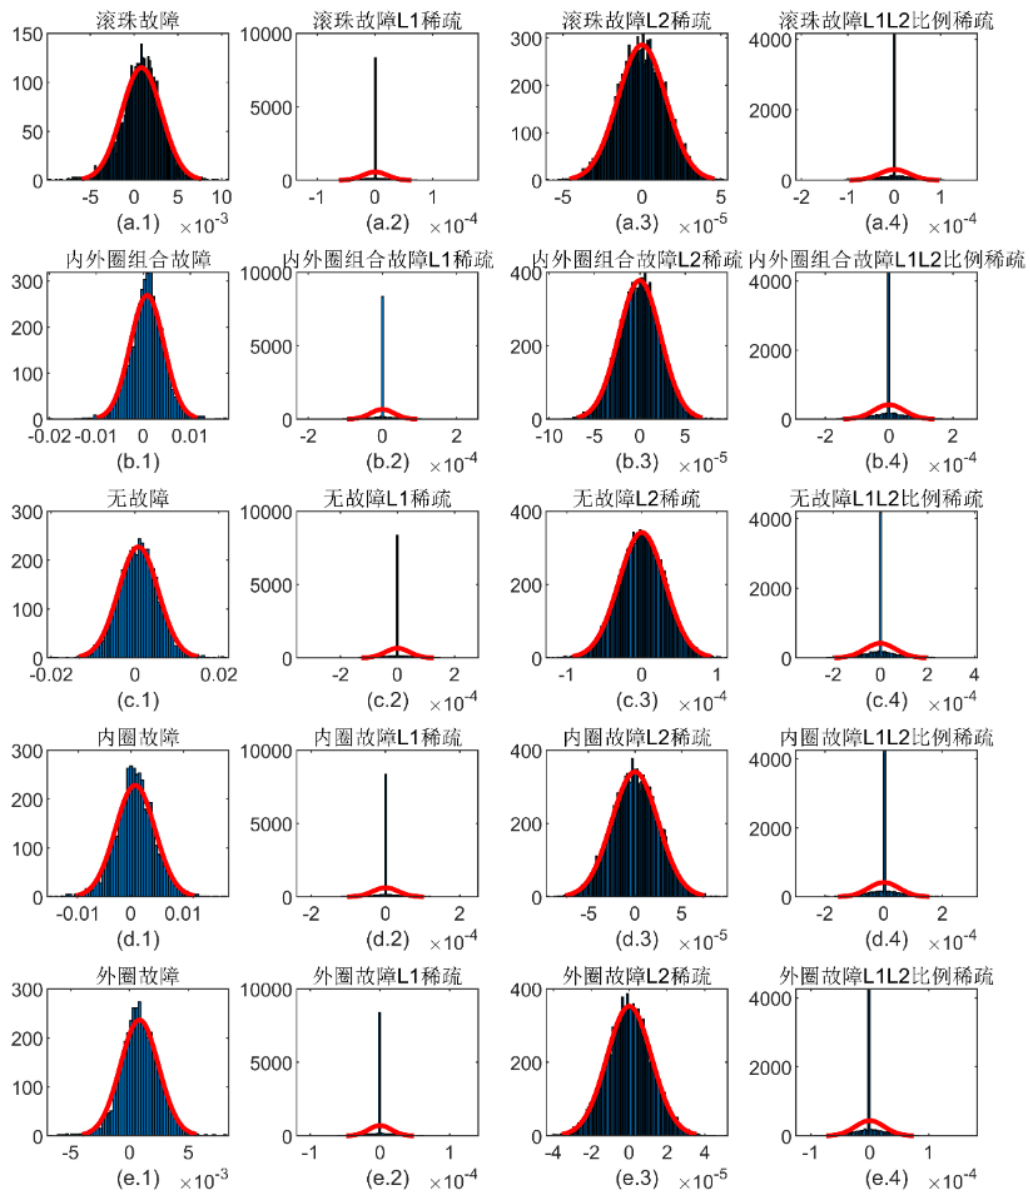


图4-7 不同故障状态下的密度分布曲线



4.滚动轴承迁移故障诊断方法



香农信息熵

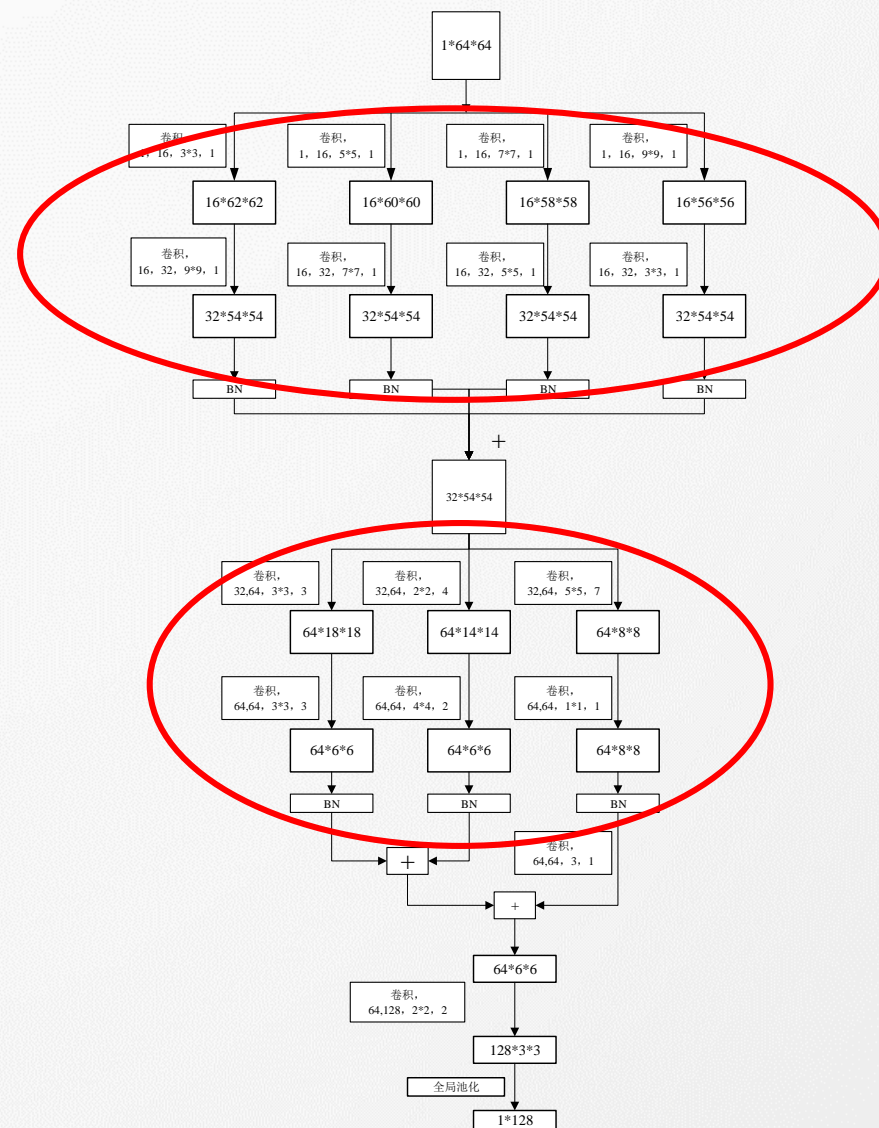
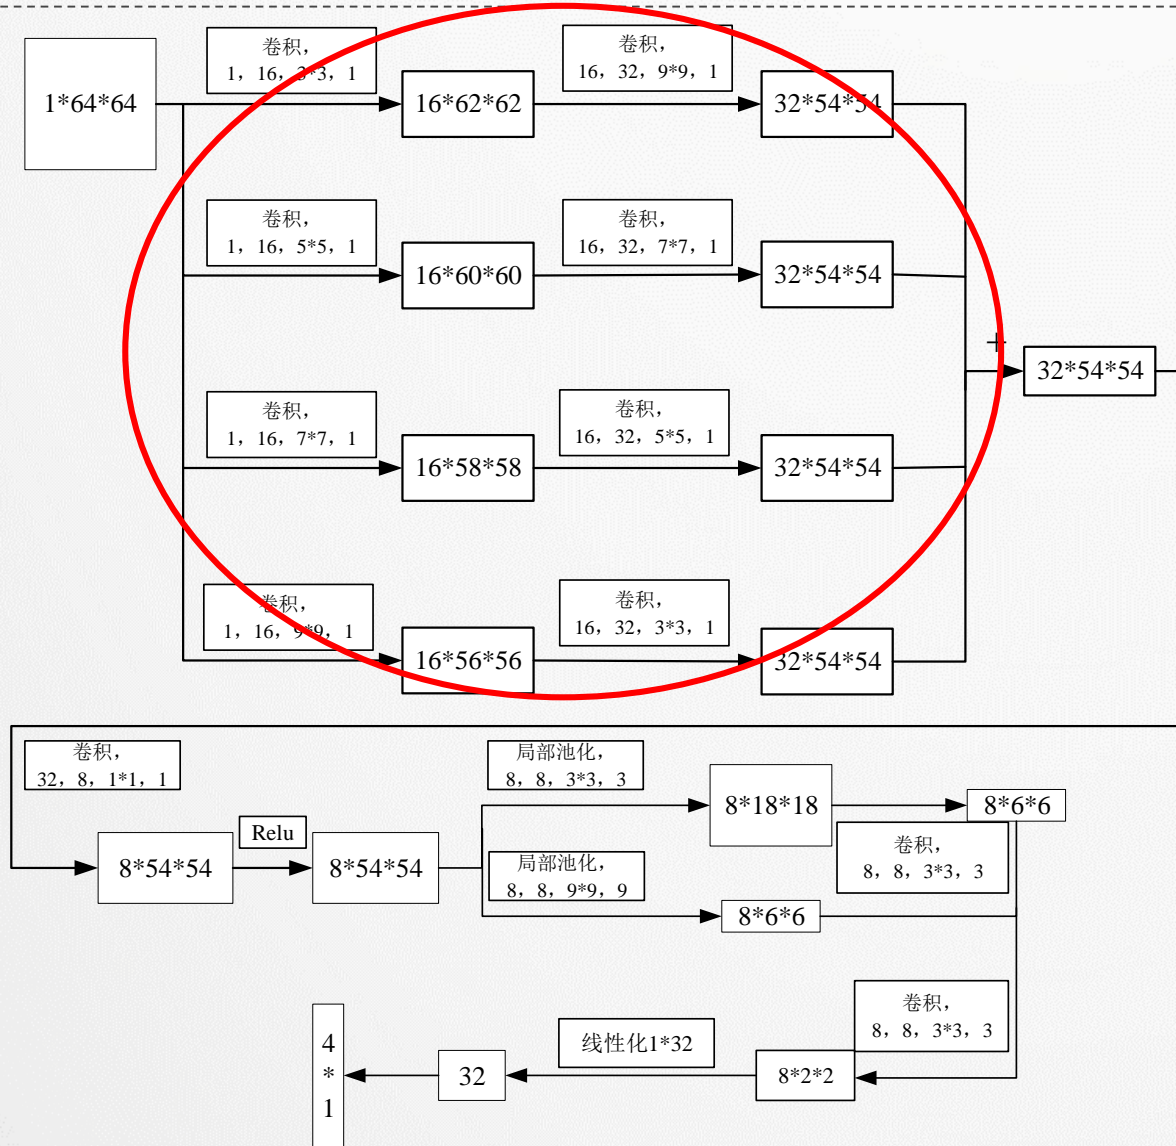
$$H(X) = -\sum_{i=1}^n p(x_i) \log p(x_i)$$

表 4-1. 故障信号不同类型的香农熵计算结果

	原始信号	L1稀疏	L2稀疏	L1L2组合稀疏
滚珠故障	3.8692	1.9983	4.1533	2.7311
内外圈故障	3.6453	1.9859	3.9646	2.7400
正常状态	3.9030	1.9969	4.1041	2.7552
内圈故障	3.8870	2.0327	4.1106	2.7458
外圈故障	3.8230	1.9367	4.0606	2.6914



4.滚动轴承迁移故障诊断方法





4.滚动轴承迁移故障诊断方法




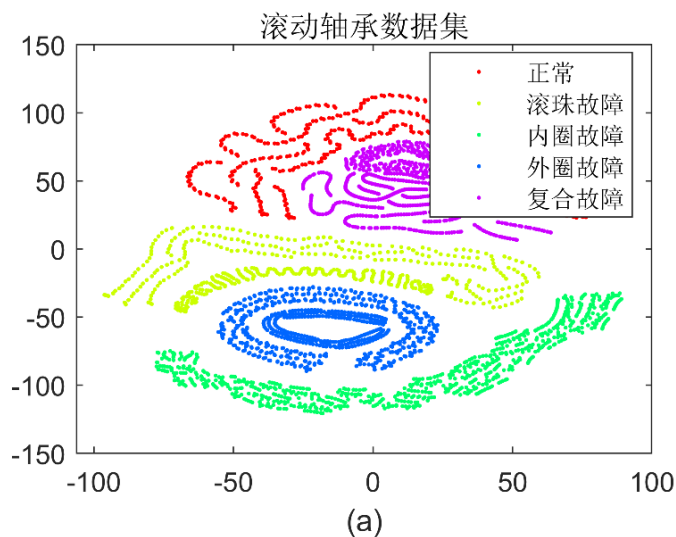


图4-10 滚动轴承数据集作为源域，齿轮数据集作为目标域



4.滚动轴承迁移故障诊断方法




图4-11 三种卷积神经网络在随机超参数分布下的两种迁移策略效果



4.滚动轴承迁移故障诊断方法

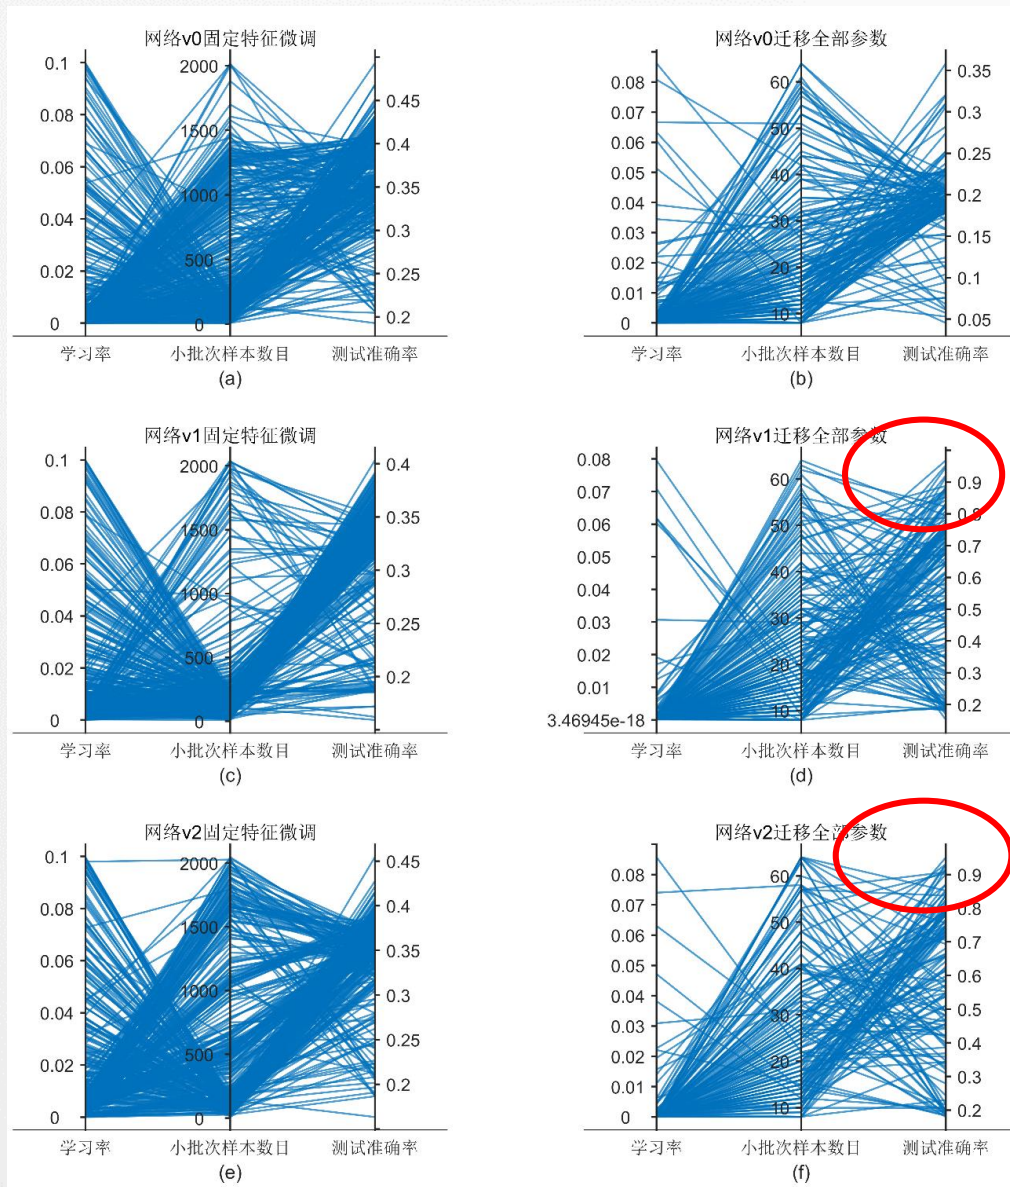



图4-12 三种网络结构在不同的超参数下的迁移结果对比的平行线图



第五部分

结论与展望





结论

(1)提出了利用单齿仿真数据进行故障诊断数据集制作，利用**自编码器进行数据增强**的方法，探索了用于**评估多个模型效率与性能的方法**。

(2)提出了利用行星轮系中各个零件仿真数据实现**振动数据升维**同时**复用经典网络**进行故障诊断的方法。同时，提出了**逐层冻结网络参数的最优超参数搜索方法**。

(3)提出了从**滚动轴承到齿轮**数据的深度迁移方法。在源域中利用压缩感知方法进行**稀疏特征**提取，制作预训练模型**加速超参数搜索**过程，并且比较了特征微调和全局参数调节两种方法在迁移学习中的适用性。



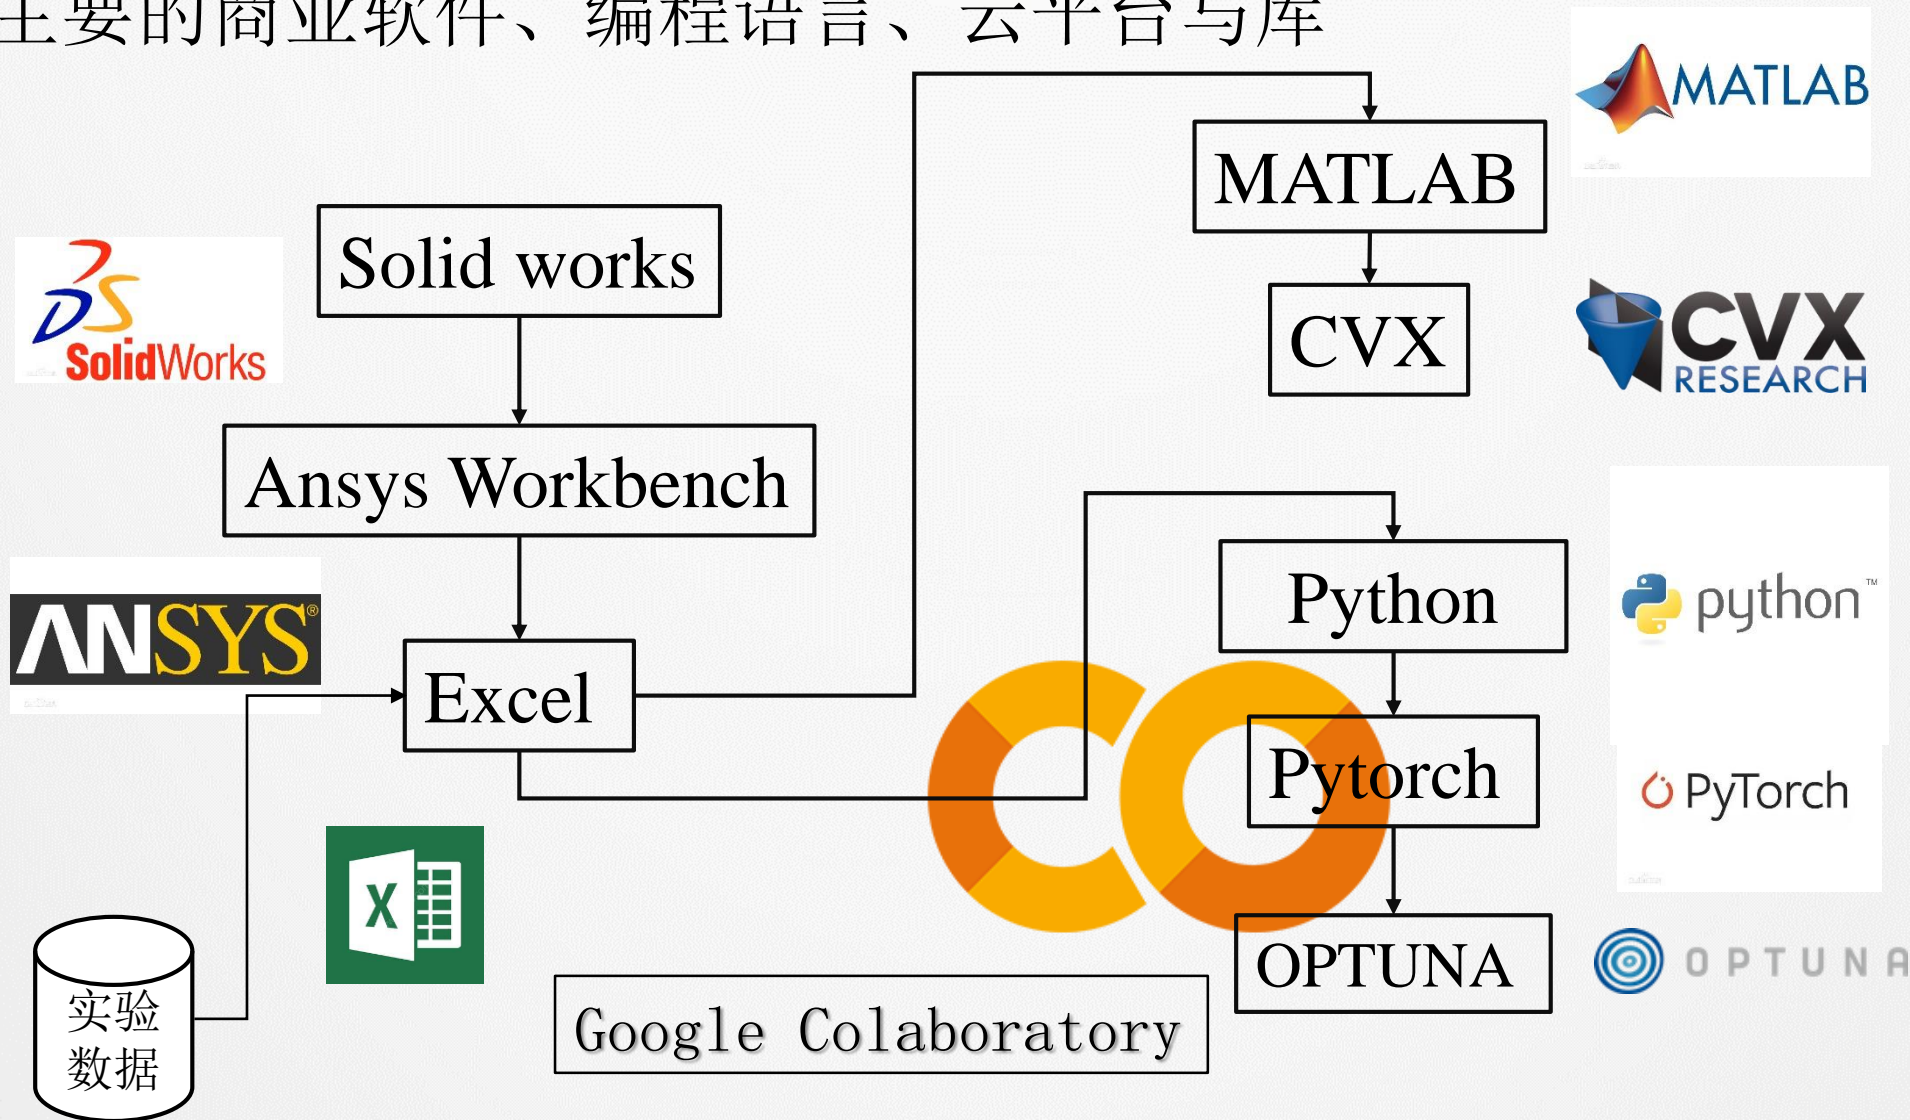
展望

本文中提及到的仿真数据与实验采集数据的融合发展，对于许多工业数据不完整或者无法直接获得工业数据的情形下，是一个很好的补充思路。所以**多源数据融合**、**虚拟仿真数据与工业采集数据融合**有很高的应用前景。

将深度学习理论应用在风电机组故障诊断领域，这种模式值得进一步深入挖掘和探索。深度学习领域实际上包含了很多的子领域，例如**少样本学习**、**增量学习（终身学习）**、**元学习**等，将其中的几种方法的优势进行吸收，重新设计模型与参数，这会是一个可以发展和研究的方向。



主要的商业软件、编程语言、云平台与库





1. **Wang X**, Liu W.Y, Zhang Y, Gu H. A novel wind turbine fault diagnosis method based on generator current analysis [J]. Journal of Vibroengineering. 2020, 22 (8): 1758-1769.(EI检索: 20210309788780)
2. **X. Wang**, W. Liu and M. Shan. Fault Diagnosis Analysis of Wind Turbine Gear Based on Transfer Function Model[C]. 2019 Prognostics and System Health Management Conference (PHM-Qingdao), 2019:1-5. (EI检索: 20200408061025)
3. Shan M, Liu W, **Wang X**, et al. A novel Robot Joint Bearing fault diagnosis method based on VMD in BP neural network[C]. International conference on ubiquitous robots and ambient intelligence, 2019: 760-764. (EI检索: 20193307314020)
4. He Ren, Wenyi Liu, Mengchen Shan, **Xin Wang**. A new wind turbine health condition monitoring method based on VMD-MPE and feature-based transfer learning [J]. Measurement, 2019, 148. (SCI检索: 000487930000022)



谢谢！
