

基于时序深度融合网络的振动故障诊断系统 在汽轮发电机组上的研究及应用

何小锋, 刘晓锋

江苏方天电力技术有限公司, 江苏 南京 211102

Research and Application of Vibration Fault Diagnosis System based on Timing Deep Integration Network on Steam Turbine Generator Set

HE Xiaofeng, LIU Xiaofeng

Jiangsu Frontier Electric Technologies Co., Ltd., Nanjing

摘要: 为了将最新的深度学习智能算法应用到汽轮发电机组振动故障诊断领域, 推进汽轮发电机组振动故障智能诊断的进步, 采用了深度学习结合专家经验的方法, 根据振动专家现场振动故障诊断的经验, 将振动故障的时序特征及运行参数对故障的影响融入到传统的深度学习算法中, 提出了基于时序深度融合网络的振动故障诊断算法, 研究了该诊断系统的相关关键技术。实验数据验证结果表明, 该算法在提高故障诊断准确率的同时, 大大提升了网络性能, 提高了网络鲁棒性和迁移能力。

关键词: 深度学习; 时序; 运行参数; 振动; 汽轮发电机组;

ABSTRACT: In order to apply the latest deep learning intelligent algorithm in the field of vibration fault diagnosis of steam turbine generator sets and promote the progress of intelligent diagnosis of vibration faults of steam turbine generator sets, the method of combining deep learning with expert experience is adopted, and according to the experience of vibration experts in on-site vibration fault diagnosis, the timing characteristics of vibration faults and the impact of operating parameters on faults are integrated into the traditional deep learning algorithms, and a vibration fault diagnosis algorithm based on the time series deep integration network is proposed. Experimental data verification results show that the algorithm greatly improves network performance, network robustness and migration ability while improving the accuracy of fault diagnosis.

KEY WORD: Deep learning; Timing; Operating parameters; Vibration; Steam turbine generator set;

0 引言

随着智能诊断技术的发展, 深度学习算法在振动故障智能诊断中的应用研究越来越深入。传统深度网络是矩阵卷积运算, 往往关注故障的准静态信息而忽视故障的发展趋势特征来对故障进行模式识别。很多基于深度学习算法的故障诊断方法研究已经在实验室得到验证, 然而深度学习在汽轮发电机组上的故障诊断其实更加复杂和困难。实际上, 传统的深度卷积网络往往特别关注故障信号的准静态特性, 即在较短的时间内每个频率的幅值和相位特征, 例如旋转机械动静部件之间的碰撞摩擦故障, 若此故障发生在一个小转子上, 它会引发多个频率特性, 深度网络输入准静态特征更丰富, 但如果故障发生在汽轮发电机

组的大转子上, 则其高频特性极其微不足道, 准静态特征减弱, 导致深度学习特征减少、诊断效果下降。汽轮发电机组故障信号往往随时间变化, 具有强发展趋势特征, 在工况变化较大的情况下, 故障会引起转子的工频振动值和相位等相关信息随时间变化, 这些信号的时间序列特征往往被传统深度学习网络忽略, 导致现有方法无法达到更好的效果。现有的一些基于 CNN 的故障诊断方法在一定程度上解决时间尺度问题的同时, 尝试使用多尺度卷积的方式自动学习特征, 但并没有直接很好地处理长时间序列的特征。另一种方法采用递归神经网络(RNNs)处理转子时间序列特征, 但没有充分利用准静态特征。因此, 深度学习网络进行故障诊断时, 将时间序列特征和准静

态特征有机融合并合理利用具有重要意义^[1]。

现有的深度学习在旋转机械领域大多数为纯振动的诊断算法，没有深入结合故障机理，只注重振动信号而不考虑运行参数下的异构耦合问题。而汽轮发电机组的振动故障往往与运行参数有关，比如汽轮机的负荷、轴瓦温度、真空、凝汽器压力等物性参数与其故障是有关的。运行参数在纯振动分析的故障诊断当中被忽略，而专家诊断时往往会结合运行参数对其故障进行综合诊断，对分析原因来说考虑运行参数是必要的。

1 提取时序和准静态特征

旋转机械可以在不同的转速和工作条件下运转。信号的采集频率被设置为旋转频率的倍数，采用同步整周期采样的方式，可以消除转速变化对特征提取时的影响，如果信号的采样频率不是旋转频率的相同倍数，不同的旋转速度将导致提取的时序特征和准静态特征有很大的差异，这时候要考虑采用转速信息的振动信号，这种差异在处理的时候应予以考虑，为着重讨论算法，本文涉及算法均在同步整周期中讨论。如上文所说的，将振动波形的时间序列和准静态信息提取出来是一项挑战。其中时间序列信息要包含故障在一段较长时间（多个旋转周期）范围内特征频率变化的信息，深度信息则要包含在较短时间里（几个旋转周期）各倍频的信息。

1.1 时间序列特征提取

A. 快速傅里叶变换获取频域特征

提取时间序列特征的方法采用的是快速傅里叶变换（FFT）和时间滑动平移方式。对于连续信号的频谱分析时，大多数采用快速傅里叶变换（FFT）法，傅里叶变换本质上属于谐波分析，其实质是通过线性组合的方式，将一个周期函数变成若干个三角函数，而 FFT 则是快速实现离散傅里叶变换的一种算法，此算法可以将信号中各个频率成分的特征提取出来。

若有实数领域或者复数领域的一个离散时间序列 $(x_0, x_1, \dots, x_t, \dots, x_{M-1})$ $M \in N$ ，且该序列绝对值累加求和的结果小于正无穷，其离散傅里叶变换（DFT）如式（1）所示：

$$X(k) = \sum_{m=0}^{M-1} x(m)W_M^{mk} \quad k=0,1,\dots,M-1$$

其逆变换如式（2）所示：

$$x(m) = \frac{1}{M} \sum_{k=0}^{M-1} X(k)W_M^{-mk} \quad m=0,1,\dots,M-1$$

$$\text{其中有：} \quad W_M^{mk} = e^{-j\frac{2\pi}{M}mk}$$

FFT 是将 DFT 优化结构、降低运算次数以及规避重复性计算优化后得到的算法。将几个同步整周期时间内的原始波形经过 FFT 变换后可以得到这段较短时间内的振动波形幅频特性，在频谱图中可以得到各个频率下信号的幅值大小，而这个是较短时间内的各个频率的特征，其反应了在短时间内能量在频率上的准静态分布。此时的信息包含的是短时内的波形特征，并没有展示波形的时间变化特征，此时需要对其在时间上进行处理才能充分展示其时间序列特征。

设备发生故障时往往可以从一些特征频率中得到表征，故障特征频率（FCF）也是传统人工故障诊断时非常重要的领域知识。从 FFT 变换后的结果里提取特征频率的值，再利用此信息对故障进行下一步诊断，不仅可以减少输入的数据量大小还可以提高算法的计算速度。

B. 滑动平移获得时间序列特征

在时间方向上，对原始波形 $(x_0, x_1, \dots, x_t, \dots, x_{M-1})$ 连续使用上述 FFT 变换，就可以得到不同时间下波形频率 f_i 、相位 ϕ_i 和幅值 A_i 信息。再从中提取特征频率（FCF）的幅值 $FCFA_i$ 和相位 $FCF\phi$ ，用这样方式得到特征频率在时间上变化的规律。

这样的时间序列特征还无法将其输入到时序处理网络当中，还要对其进行时序滑动平移的拆分处理，将其沿着时间方向切分成一份一份才能输入网络并训练。假设经过 FFT 并提取特征频率后的结果 $FCFA_i$ or $FCF\phi_i$ 是一个在时间上的离散

时序 $X = (X_0, X_1, \dots, X_t, \dots, X_{m-1})$ 其中 $X_t \in (0, m-1)$ 是在一个同步整周期里 FFT 变换

后特征频率的幅值或相位。设 j 为滑动平移的长度， Z_k 为滑动平移后的结果，滑动平移后：

$$Z_k = (X_k, X_{k+1}, \dots, X_{k+j}) \quad k \in (0, n-j-1) \quad \text{这}$$

样得到的 Z_k 可以输入网络时序端口的时间序列特征 (TSFCF)。下图为时序特征提取的示意图：

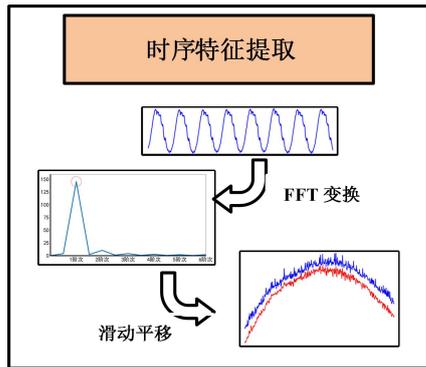


图 1 时序特征提取方法

1.2 准静态特征提取

提取准静态特征的方式是通过连续小波变换 (CWT) 达到的，CWT 采用一组小波函数对信号进行时频域分解^[2]。基于小波变换，保留了信号高频部分的分解，提高了高频区域的分辨率，使信息更加完整，避免了原始信号信息的丢失。本文采用的 CWT 方法在尺度轴上是连续的，可以保留高频信号，使准静态信息具有良好的分辨率。

因此，采用 CWT 的准静态特性作为网络的深端口。连续小波变换的过程在数学上描述为：

$$\Psi_{a,b}(t) = |a|^{-\frac{1}{2}} \Psi\left(\frac{t-b}{a}\right) \quad a, b \in \mathbb{R} \quad a \neq 0$$

$$C_a(k) = \int x(t) \bar{\Psi}_{a,b}(t) dt$$

式中 $\Psi_{a,b}(t)$ 为连续小波， $\bar{\Psi}_{a,b}(t)$ 为其复共轭，其中尺度参数 a 和平移参数 b 分别决定其形状和位移。连续小波变换继承和发展了短时傅里叶变换 (STFT) 的局部化思想。与 STFT 不同，缩放和平移参数 a 和 b 可以在时间和频率轴上调整分辨率，因此提供不同的频率分辨率和时间分辨

率。连续小波变换是信号时频分析和处理的理想工具。

信号 $x(t)$ 在 a 尺 (第 a 个) 尺度上的小波系数为 C_a ($a = 1, 2, 3, \dots, l$)， k 为时间指标 ($k = 1, 2, 3, \dots, m$)。然后，在不同尺度下得到的所有小波系数形成一个小波系数矩阵 $CWCM = [C_1, C_2, \dots, C_l]$ 。为了使得变换后的多个小波系数矩阵 $CWCMs$ 包含足够的准静态信息，在处理信号的时候原始信号 $x(t)$ 要包含三个以上同步整周期的时间长度。为了使得网络学习到最新的特征，在每一个时间序列特征 (TSFCF) 最后一段时间里取得 $x(t)$ 值，并且计算的每一个 $CWCM$ 是对应的时序信号 TSFCF 中最后时刻的信息。在同步整周期的采样方式下，处理的 $CWCM$ 会有相同的大小，如果采样频率不变当转速改变时 $CWCM$ 会改变大小，要使用算法使其具有相同尺寸。为了使得深度网络更好处理 $CWCMs$ 灰度图，所有图片要剪裁成长宽相同的大小，也就是使得 $m=l$ 。将 $CWCMs$ 数据处理完成，为进而下一步输入网络的深度端口进行训练做准备。下图为准静态特征提取示意图：

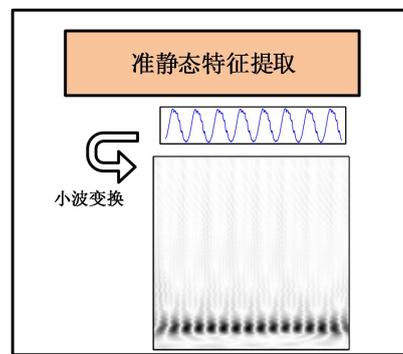


图 2 准静态特征提取方法

1.3 运行参数特征提取

汽轮机的运行中有较多和故障相关的运行参数，比如功率负荷、凝汽器压力、轴瓦温度等，用这些参数在一定程度上可以表征故障的严重程度。所以在运行参数特征提取时要结合其参数特点对其进行数据处理。汽轮机的运行物性参数在数据结构上为一维的数据深度，其特点是在时间维度上具有一定变化规律具有时间序列上的特征，所以可以对其进行时序特征的提取。下图为运行参数特征提取示意图：

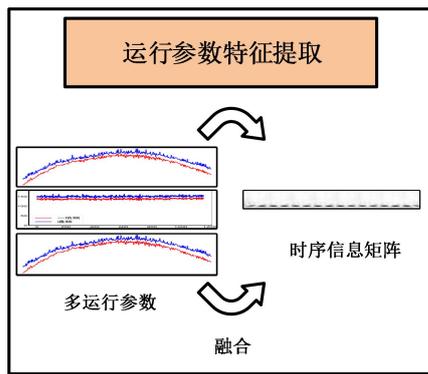


图3 运行参数特征提取方法

对于运行参数的提取可以使用时序特征提取当中滑动平移的方式^[3]。假设在一定时间内单个物性参数在序列时间上的是一个离散时序

$$X = (X_0, X_1, \dots, X_t, \dots, X_{m-1})$$

, 其中

$X_t \in (0, m-1)$ 是 0 到 $m-1$ 时刻内运行参数的真实值。则设 j 为滑动平移的长度, 设 Z_k 为滑动平移后的结果, 滑动平移后:

$$Z_k = (X_k, X_{k+1}, \dots, X_{k+j}) \quad k \in (0, n-j-1)$$

这

样得到单个运行参数在时间序列上的特征 Z_k 。此时将多个运行参数都采用滑动平移的方式处理成相同长度的时间序列, 使用并联方式将数据结构连接成一个时间的矩阵序列 Z_{kl} 。处理好的运行参数时序矩阵就可以做为网络的时序输入端口做准备。

2 网络搭建基础模块

2.1 深度可分离卷积模块

深度可分离卷积是一种与信道数等价的基数卷积(深度卷积)和分析跨信道相关性的 1×1 卷积(随后的点方向卷积)的组合^[4]。深度可分离卷积的前部分的卷积核数目与输入通道数相同, 这个卷积运算时一个卷积核只与对应的通道进行卷积操作, 卷积结果也和输入通道数相同, 后部分卷积是 1×1 的普通卷积, 卷积核会与所有通道进行卷积运算并累加, 这做就可以得到目标指定数目的卷积结果^[5]。

2.2 深度残差模块

深度残差网络是一种人工神经网络, 其目的是克服创建层次较深的普通神经网络时精度较低的问题, 换句话说, 深度残差网络的目的是使神经网络具有更深层次的高精度。深度残差网络的概念是使神经网络能够将权值更新到较浅的层(降低退化梯度)。这个概念是通过“快捷连接”实现的。网络有主体和残差边构成分别名为卷积块和残差块, 其中卷积块输入和输出的维度是不一样的, 所以不能连续串联, 它的作用是改变网络的维度; 残差块输入维度和输出维度相同, 可以串联, 用于加深网络的维度。

2.3 RNN 网络模块

Recurrent neural network(RNN) 是一类有递归隐藏单元的神经网络, 其每一时刻的输出不仅依赖于当前时刻的输入, 还与之前的输入有关。这样的结构使得其具有提取时间序列特征的能力, 可以对时间序列进行建模, 作为时序神经网络的一种选择。通常的, 一段离散时间序列假设为 $X = (X_0, X_1, \dots, X_t, \dots, X_{m-1})$, $X_t \in \mathbb{R}^j$ 作为时序 RNN 在 t 时刻下的输入, 而同一时间步的隐藏状态 $h_t \in \mathbb{R}^d$ 更新式子如下:

$$h_t = f(h_{t-1}, x_t) = f(Uh_{t-1} + Wx_t + b)$$

其中 U 、 W 、 b 都是可以学习更新的参数, $U_t \in \mathbb{R}^{d \times d}$, $W_t \in \mathbb{R}^{d \times j}$, $b \in \mathbb{R}^d$, m 是时序的长度, j 是网络输入长度, d 是隐层的大小, f 是一个非线性的函数。

2.4 LSTM 网络模块

由于 RNN 存在梯度消失问题, Hochreiter 和 Schmidhuber 提出了长短期记忆(LSTM)来解决这个问题。LSTM 除了隐藏状态单元 h_t 以外还保留一个储存单元 c_t , 记忆单元行为由三个门来实现, 输入门 i_t , 输出门 o_t , 和遗忘门 f_t 。更新方程式如下:

$$i_t = \text{sigmoid}(U_i h_{t-1} + W_i x_t + b_i)$$

$$f_t = \text{sigmoid}(U_f h_{t-1} + W_f x_t + b_f)$$

$$o_t = \text{sigmoid}(U_o h_{t-1} + W_o x_t + b_o)$$

$$\hat{c}_t = \tanh(U_c h_{t-1} + W_c x_t + b_c)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \hat{c}_t$$

$$h_t = o_t \circ \tanh(c_t)$$

其中 $U_t \in^{d \times d}$, $W_t \in^{d \times j}$, $b \in^d$, 都是可以学习更新的参数。

运算符 \circ 表示元素的乘法运算。在时刻 t 时, 首先通过输入值 x_t 和隐藏状态 h_{t-1} 的函数得到遗忘门 f_t 。当遗忘门的值接近 1 时, 来自最后一个记忆单元 c_{t-1} 的信息将被保留, 否则将被遗忘。然后, 将新输入状态和原隐藏状态的函数组成一个输入门, 并加入到存储单元中成为 c_t 。最后, 输出门将决定应该从存储单元中取出什么以形成一个新的隐藏状态 h_t 。

3 网络搭建和异构信息融合

为了搭建满足要求的诊断网络, 我们将时间序列和深度融合的卷积网络作为此网络的一个基础结构, 其整体由三个部分组成:

3.1 深度网络模块

这部分是整体网络当中的深度网络模块, 此为一个并联模块结构, 其与时序模块进行并联, 目的是能够对输入的准静态特征 CWCMs 矩阵进行学习。深度模块由以下三个结构组成

A 输入端。 为了满足深度模块能对 CWCMs 进行学习, 其输入端需要满足接收 3-D 矩阵的结构。此处输入结构需要满足能够对矩阵进行运算需求, 一般设置为一个多通道的普通卷积模块对初步特征进行输入和卷积操作。

B 卷积模块。 此是深度网络的重要部分, 是深度网络对深度特征学习的关键结构。这个部

分的目的是为了能够对矩阵进行运算, 并对其中的特征进行学习, 可以称之为主干深度特征提取模块。这只是一个基础的网络结构, 并不限制其中的网络细节, 所以凡是能够对其进行特征处理的网络, 我们都可以在此结构中将其进行替换或者优化组合, 这也是此结构的灵活和多变的地方, 可以使其运用到更多合适的场景。由于没有限制深度模块的结构, 此模块可以使用传统 CNN 结构对其进行深度特征提取, 也可以替换为可以减少计算量的深度可分离卷积模块, 或者可以减少过拟合的残差网络模块, 使其网络更好的达到特征提取目的。

C 展平层。 为了使得深度模块能与时序模块的特征进行融合, 我们需要对深度模块的运算结果进行展平, 这样两者特征才可以统一到同一个维度, 必要的时候展平层内部还需要包含一个全连接层对其特征进一步处理并控制深度特征在整体网络当中的占比。

3.2 时序网络模块

此部分为整体网络中的时序模块, 其同样为一个并联模块结构, 其与深度网络进行并联, 目的是能够对输入的时间序列特征进行学习。时序模块包括以下结构:

A 输入端。 为了满足时间序列模块能对进行学习, 其输入端结构要满足能接收不同长度的向量, 通常是不定长度的向量输入端。

B 时序卷积模块。 此部分是时序模块重要的部分, 是提取时间序列特征的主要结构, 可以称之为主干时序特征提取模块。这是一个基础的网络结构, 并不限制内在的卷积模块类型, 凡是能够对时间序列进行特征提取的网络都可以将其替换到这个网络结构当中, 使其更好达到提取时间序列特征目的。由于此结构的灵活多变, 我们可以采用传统的全连接网络结构, 还可以是 RNN 网络结构或者是效果更好的 LSTM 网络结构对其进行替换。更多地, 在卷积之后还要连接一个全连接层对其特征进一步处理并控制时序特征在整体网络当中的占比。

3.3 特征全连接网络

在深度模块和时序模块之后, 两者都用了全

连接网络分别对其进行权重分配，在这两者之后需要串联一个全连接网络对两者特征进行融合并能够正确输出类别信息。此部分包括以下两结构：

A 连接模块。此模块为几层全连接结构，连接深度模块和时序模块的输出特征，融合两者特征并进行全连接运算。

B 输出模块。最后的输出部分目的是能准确输出故障类别，结构为连接上一全连接层的一个分类层，通常是采用一个 softmax 层达到分类的目的。

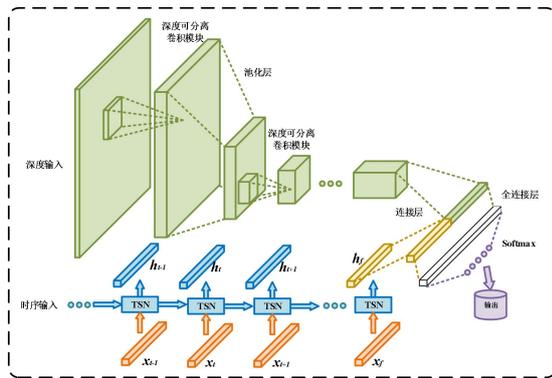


图 4 时序深度网络结构

4 实验验证及分析

在实验台故障诊断中，转子不平衡、不对中、轴承座松动和接触碰磨四种常见故障被用来验证所提出的诊断方法。由于不同类型的传感器对不同故障的敏感程度不同，不同类型的传感器数据被用于不同的故障模式。位移传感器用于诊断转子的不平衡和不对中，而加速度传感器用于诊断轴承座松动和接触碰磨。

本实验研究目的是验证时序深度融合网络对旋转机械轴系故障诊断的效果。通用性是大多数智能故障诊断算法的关键，通用性水平的提高会大大降低设计和维护成本。为了验证所提出的时序深度融合故障诊断方法的通用性，本节将经过训练的时序深度融合网络应用于汽轮机转子实验台的故障诊断。

表 1 显示了使用转子实验台数据训练得到的时序深度融合网络、纯时序网络、纯深度网络对汽轮机转子实验台进行故障诊断的结果。从表中可以看出，所有故障的诊断结果都大于 80%，且时序深度融合网络对各个故障的诊断效果都高于另外两者，这表明所提出的时序深度融合方法是

一种旋转机械故障诊断的通用解决方案。如果获取到新设备的更多数据，可以对已经得到的模型进行进一步的训练，以获得更好的诊断性能。

表 1 转子试验台网络诊断结果

为了验证网络的迁移诊断能力，以及其故障

故障模式	样本数量	正确数量	时序深度网络准确率	时序网络准确率	深度网络准确率
正常	12	113	94%	85%	93%
转子不对中	120	114	95%	91%	94%
转子不平衡	120	115	96%	82%	86%
接触碰磨	120	118	98%	95%	87%
轴承座松动	120	115	96%	58%	95%

为验证诊断方法的通用性，对汽轮机发电机组进行迁移诊断测试。训练集采用望亭电厂 4 号机组、中电投协鑫电厂 2 号机组、陈家港电厂 1 号机组、国电谏壁电厂 1 号机组、江苏扬二厂 2 号机组等电厂汽轮机运行时健康及非健康状态的运行振动数据，对待检验的网络模型进行训练。验证采用江苏常熟发电有限公司二期 2×1050MW 的机组 5 号机组，汽轮机是由上海汽轮机有限公司和德国西门子公司联合设计制造的超超临界、一次中间再热、单轴、四缸四排汽、双背压、八级回热抽汽、反动式汽轮机 N1050-26.25/600/600，机组设计额定输出功率为 1050MW。汽轮机结构如下：

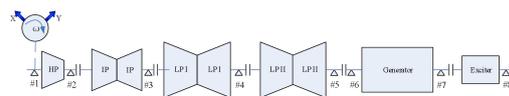


图 5 振动测点布置

测试数据包含正常状态、碰磨和不平衡故障，采用单轴瓦的诊断方式，对传统深度网络和深度融合网络做迁移诊断测试。从图 6 网络诊断结果拓扑结构图中可知，颜色越深代表其诊断效果越好，传统纯深度网络对汽轮机组的诊断效果欠佳，对不平衡和碰磨故障并没有很好的区分效果，而融合了时序网络则会大大提升了网络性能，提高了网络鲁棒性和迁移能力。

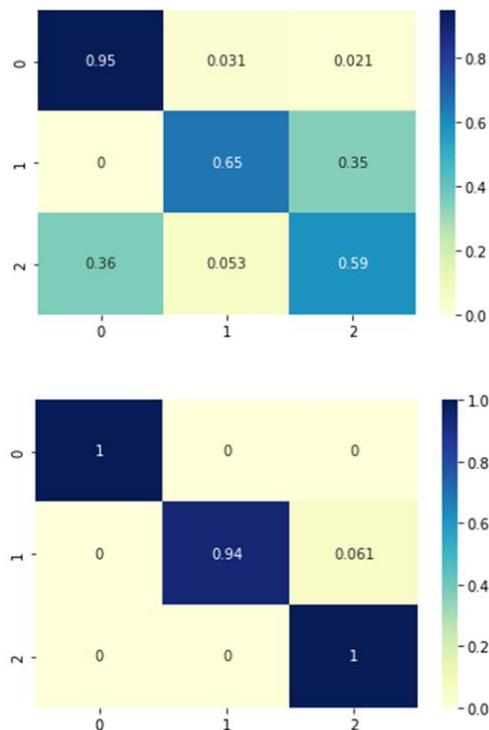


图 6 深度网络诊断效果 (上) 时序深度融合网络诊断效果 (下) (1.正常状态、2.碰磨、3.不平衡)

从诊断结果上来看融合了时序的深度网络对汽轮机的常见故障诊断有较好的效果, 故障诊断效果从 60% 提升到 90% 以上, 相比起传统深度网络有较大提升。

表 2 转子试验台网络诊断结果

故障模式	样本数	正确数	时序深度网络准确率	时序网络准确率	深度网络准确率
正常	120	120	100%	100%	95%
转子不平衡	120	113	94%	88%	89%
接触碰磨	120	120	100%	87%	85%

4 结语

深度学习算法在图像识别上取得了重大成功, 它具有对多维原始输入的处理能力, 能从数据中直接学习高级特征, 减少了复杂的特征提取算法和对专业的领域知识的依赖, 同时又具有良

好的迁移性, 弥补了传统智能诊断算法在振动领域上应用的不足, 使其在振动智能诊断上成为热点。本文结合现场分析经验, 认为振动趋势及运行参数对振动的故障诊断具有非常重要的作用, 提出了基于时序深度融合网络的振动故障诊断系统, 并在汽轮发电机机组上进行研究应用, 取得了较好的效果。但深度学习算法对样本数据量的要求较高, 因此目前仅研究了碰磨、质量不平衡等几中常见故障, 汽轮发电机组的其他故障还有待补充及完善。

致谢

感谢方天公司在项目研究上提供的支持, 感谢同事刘晓锋专家及母校杨老师在项目研究上提供的指导与帮助, 一并感谢所有在课题研究中提供帮助及付出劳动的同事及朋友们, 谢谢!

参 考 文 献

- [1] 杨涛. 基于小波分时尺度矩特征的多状态信息融合振动故障诊断和预测方法研究:[博士学位论文]. 武汉: 华中科技大学图书馆, 2009.
- [2] Wang Y, He Z, Zi Y. Enhancement of signal denoising and multiple fault signatures detecting in rotating machinery using dual-tree complex wavelet transform. *Mechanical Systems and Signal Processing*, 2010, 24(1):119~137.
- [3] Tian Y, Ma J, Lu C, et al. Rolling bearing fault diagnosis under variable conditions using LMD-SVD and extreme learning machine. *Mechanism and Machine Theory*, 2015, 90:175~186.
- [4] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks. in: *Proceedings of the 25th International Conference on Neural Information Processing Systems*. USA: Curran Associates Inc., 2012. 1097~1105.
- [5] 周奇才, 刘星辰, 赵炯等. 旋转机械一维深度卷积神经网络故障诊断研究. *振动与冲击*, 2018, 37(23):31~37.

收稿日期:

作者简介:

何小锋 (1983-), 男, 湖北, 研究生, 高工, 旋转机械振动分析及处理