

智能振动监测

Ver1.1

Revisions

版本	日期	说明
1.0	2016.09.06	创建初始版本
1.1	2017.01.30	修改部分文字

1. 从老司机说起

当一个司机开车的时候，他会听到引擎产生的声音，通常这种声音是一种均匀的近似白噪音的声音。某个瞬间，司机听到了一声不曾听过的特殊噪音，这种特殊噪音，先是偶尔出现，但随后出现的频率逐渐提高，于是司机认为引擎可能出现了故障，把车子开到修理厂进行检查。

值得注意的是，在这个过程中，虽然司机没有事先经过对机械故障进行辨识的专业训练，也没有学习过特定故障的声音，更没有异于常人的敏锐听力，但他还是成功了进行了故障预警。

司机的判断逻辑，存在三个假设：

- 引擎的运动是一个连续的过程，其产生的噪音也应该具备连续性；
- 引擎的初始状态是一个好的状态；
- 引擎的异常状态不具备连续性，即，故障不是一个可持续的状态；

因此，在刚刚开始开车的时候，司机的耳朵采集了大量的被假设为“正常”的声音样本，头脑中记录了一批“正常样本集”。然后，司机听到了不吻合正常样本的声音特征后，识别出了“未知样本”，这种样本被假设为异常的。并且，通过对异常样本出现的时间特征进行统计分析，得出其具备故障随着发展提升频率的假设。

和故障不太相同的是老化，这是一个渐进式的过程，幸好，人脑有记忆能力，可以将当前样本和记忆中以前的样本进行比较，并对差异进行分析。典型的，司机会发现，虽然噪音的基本特征和正常的时候是吻合的，但声音总体加大了，或者声音中特定的成分加大了，因此司机就做出了引擎虽然是“正常”工作，但状态已经变差的推理。当这种劣化到了一定程度，并且结合开车的时间/里程等数据，司机也会做出进行维修的正确选择。

因此，无论是突然出现了异常，还是渐进式的劣化，司机都是基于和正常状态进行对比，寻找变化的成分，并基于改变的程度进行状态评估。即，司机不是去分析“故障”，而是分析“不正常”。

2. 机器学习原理

机器学习的原理，是先给人工智能“喂”一套全面的样本数据库，不仅包括正常样本，还包括所有的故障样本，人工智能通过算法发现各种状态的特征，从而获取判断状态的能力。

我们的方法大概是这样的：

- 1) 我们做一个自动化采集系统，对被测设备进行的数据采集。
- 2) 我们把这些数据灌到一个“分类器”算法里面，这种算法会给出一个“区分度”指标。
- 3) 我们用某种统计计算，找出来综合区分度最佳的系统参数，得到一个确定结论（如正常或是某种异常）。

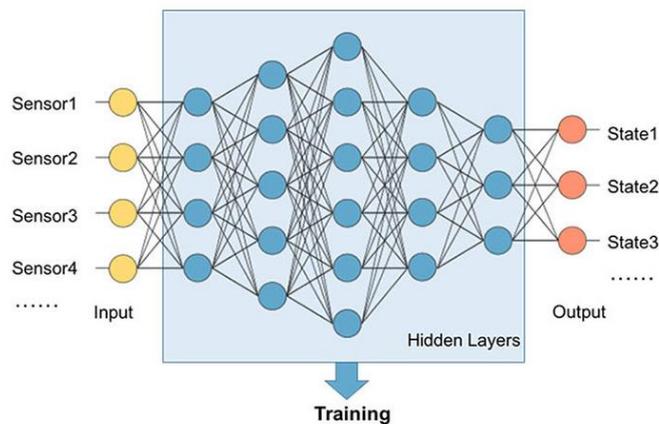


图 1 机器学习

值得注意的是，我们需要采样大量的数据，这个“大”不仅指数据的数量，更指“维度”。对于机器监测来说，就是在多个位置、全方位地采集振动数据（Sensor1, Sensor2, ..., SensorN）。

比如：

一个设备有 M 个监测点，每个监测点采集三轴上的加速度，构成了一个 $M*3$ 维度的振动向量，可以记做 V 。

设备的状态是一个有限的集合，这个集合包含了正常状态和一些已知的故障状态。对于设备的一个状态，记做 S 。

所谓的“样本集合”，就是建立一个振动向量 V 和状态 S 的对应关系，形如：

$V1 \rightarrow S1$ （正常状态）

$V2 \rightarrow S1$ （正常状态）

$V3 \rightarrow S1$ （正常状态）

$V4 \rightarrow S2$ （不对中）

$V5 \rightarrow S2$ （不对中）

$V6 \rightarrow S3$ （轴承磨损）

$V7 \rightarrow S4$ （底座松动）

.....

$Vn \rightarrow Sn$

意思就是，这一组振动向量 $V1$ 对应正常状态 $S1$ ，那一组振动向量 Vn 对应某个故障状态 Sn ，等等。

设备监测的目标，就是从一个未知的 V 中，找到它对应的 S 。

我们定义一个振动向量的差异判断函数，即对于 Va, Vb ，它们之间的差距有多大。比如，最简单的可以用距离 $|A - B|$ 来描述两个向量是否相互接近。

有了这些基础，对于某个未知的 V ，通过和样本集合中的 V 一一进行距离计算，找到相似度最大的前 N 组，其中最多的那个状态，就是匹配状态，得出当前状态是正常、或是异常判断。

3. 特征提取和识别

从人类对声音的理解来说，人类把声音分为乐音和噪音两种，其中对于乐音的描述，主要包括三个特征：

- 强度
- 音调
- 音色

其中，强度代表声音的能量，音调代表最主要的频率成分的频率，音色代表高次谐波相对于主频的比例：

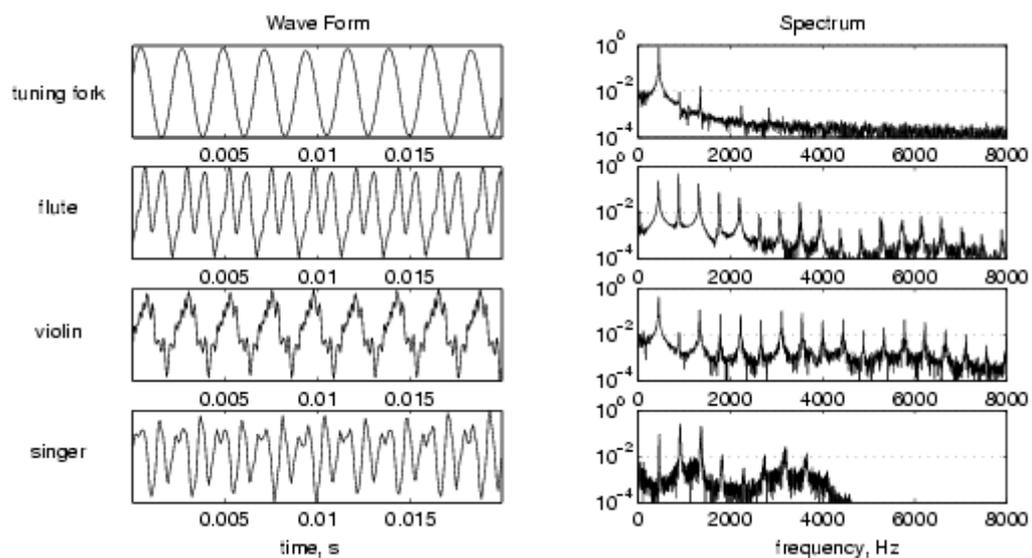


图 2 音乐

(上到下：音叉/长笛/小提琴/歌手)

频谱上可以看到，每种乐器的谐波能量分布具有显著的区别，噪音则是没有简单的频谱特征的部分，即在频谱上弥散在一个大范围内的能量成分。

振动和声音一样是一种机械振动，因此可以用类似的方式进行分析。对于振动分析，可以提取出如下的特征：

- 强度: 总能量
- 基波频率: 频谱上频率最低的峰
- 谐波比例: 基波的倍数频率的能量相对于基波的比值
- 噪音成分: 非基波/谐波部分的能量(主要指高频非谐波)

这一组值可以构成一个“特征空间”，在正常状态采集足够多的样本后，就可以统计每个特征值的分布(中心及方差)，然后即可对于一个新的振动，判断是否处于正常状态的分布内。

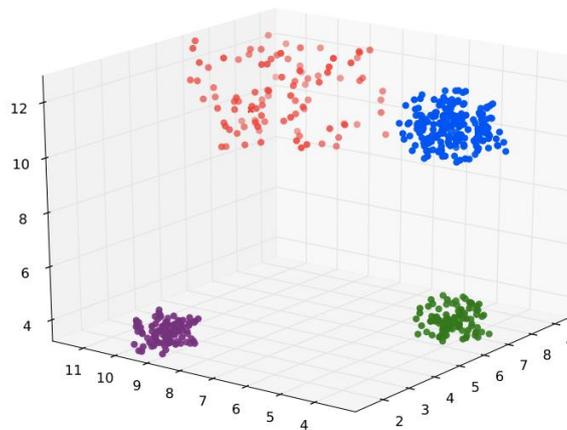


图 3 样本分类

4. 动态学习特征

虽然一般意义上说，不可能做到事先枚举所有故障的可能，但却可以在每次确定一个故障后，将其特征值加入已知状态的数据库，从而在再次遇到此故障时事先识别。

类似于当司机第一次见到某故障的时候，只知道声音是“陌生声音”，但第二次遇到即可根据经验进行判断。

古人说，见多识广。何为“见多识广”？其实就是大数据，理论上，只要传感器类型够多，采样到的数据够全面，把所有故障的数据全部记录下来，然后新来的数据一个一个的比较过去，就可以分析得出结论。

5. 智能监测的优势

机器振动监测的方式大体经历了如下时期：

- 1) 人工巡检：人工采集数据 + 人工决策
- 2) 传统在线监测：自动采集数据 + 人工决策
- 3) 智能监测：自动采集数据 + AI 辅助决策 + 人工决策

设备监测由采集数据（测）和决策（监）两部分组成，从人工巡检到智能检测，是一个自动化成分越来越大的过程。

AI（人工智能）辅助决策，可以过滤掉全部的正常情况，并对于异常情况的可能原因，基于 AI 专家系统已知的信息进行提示，并可以动态自主学习新的规则，人只需做最终的决策。

因此，人的工作量大幅度下降，工作效率极大提升。

6. 联系方式

姓名: 李先生

电话: (86)188 0181 9086

邮箱: liangfeng@wiihey.com

地址: 上海浦东张江博云路 111 号爱酷空间