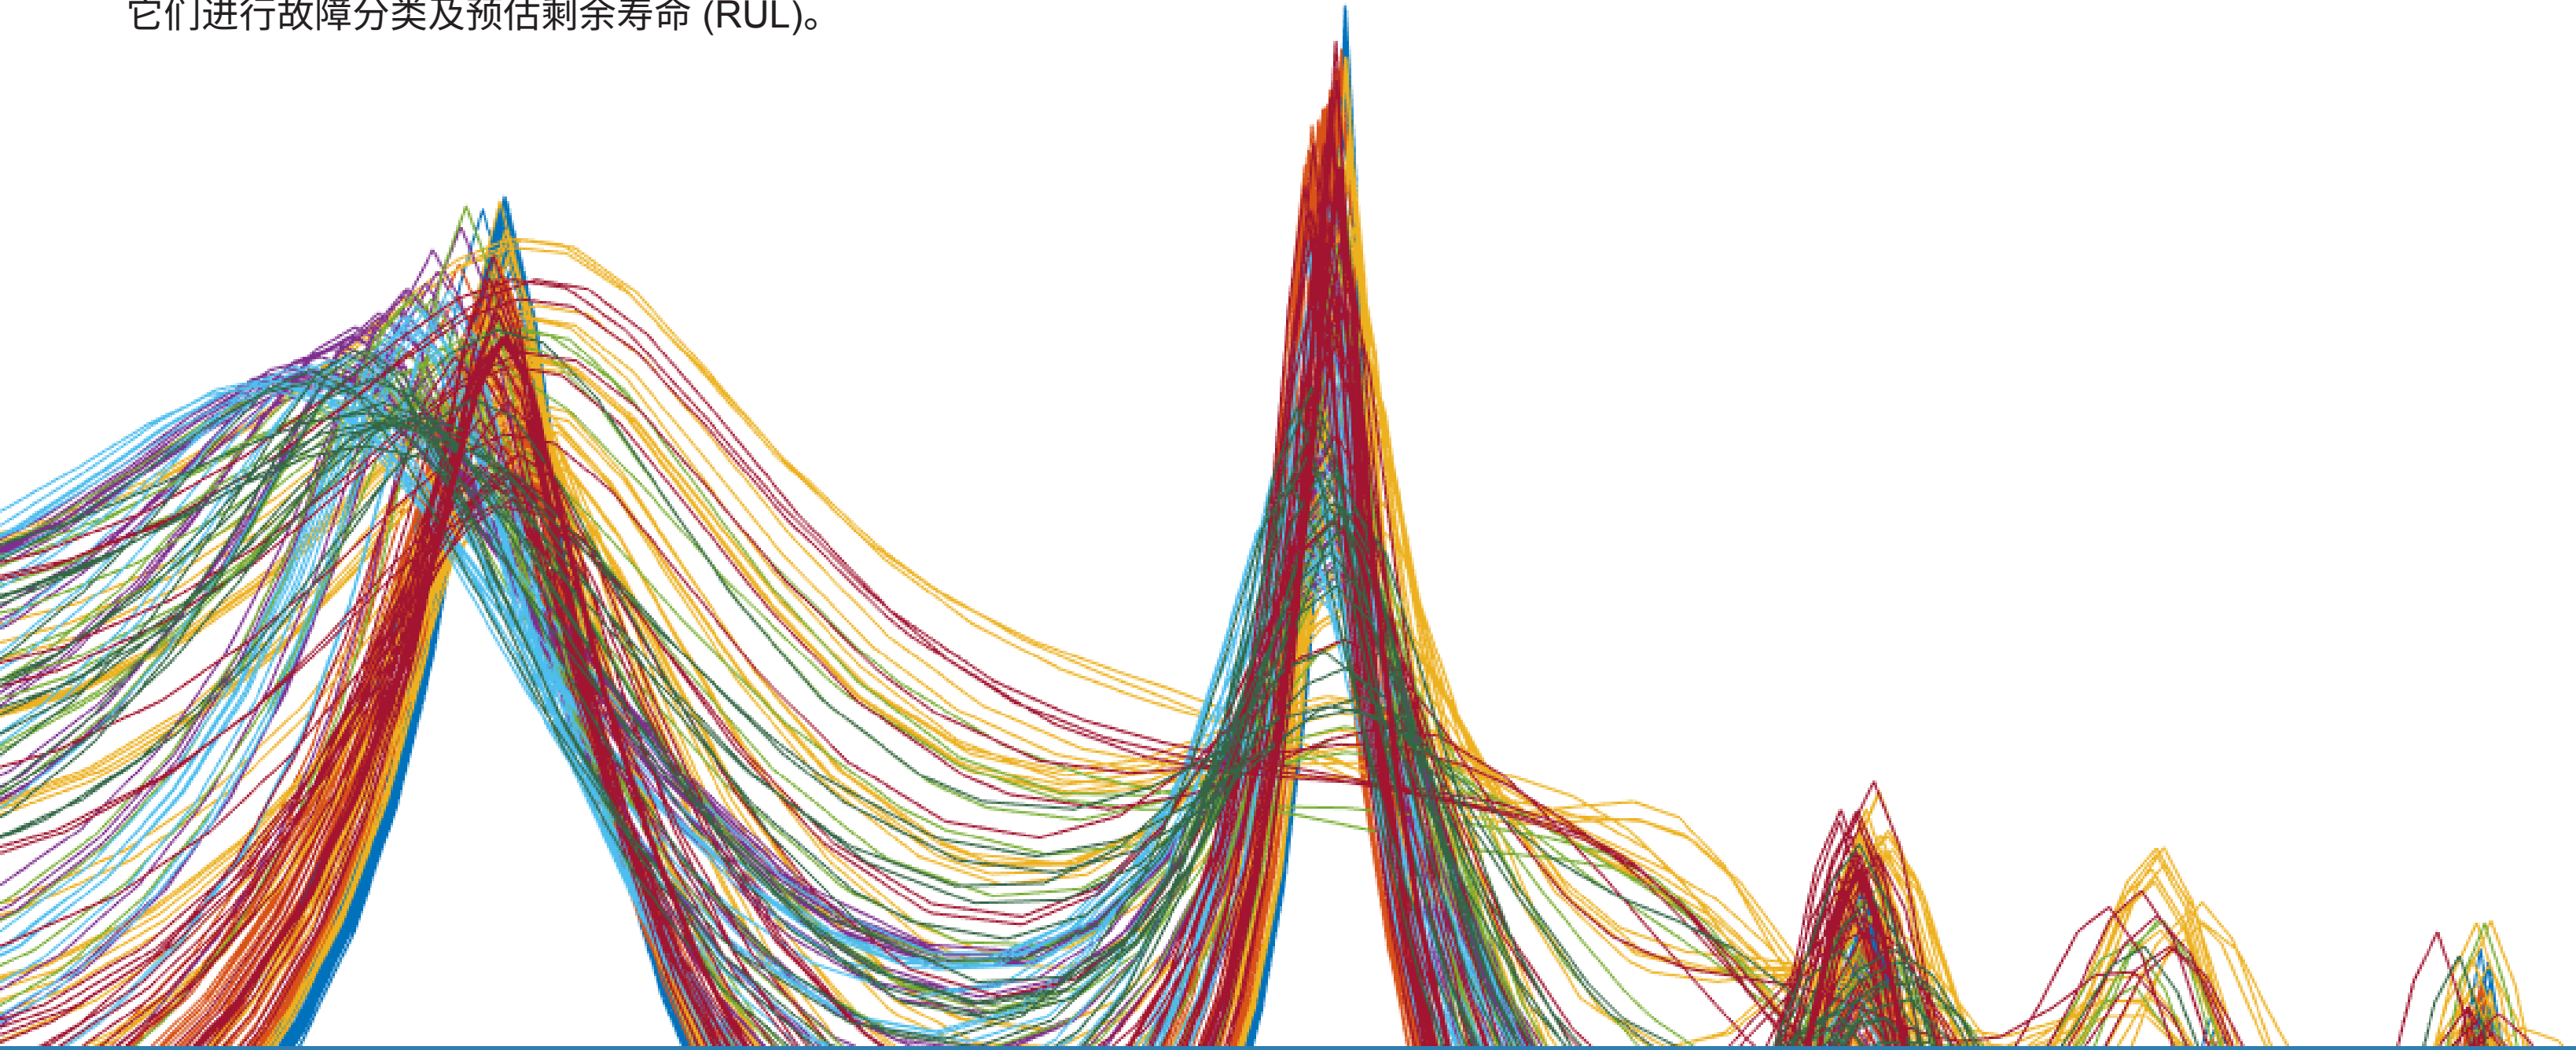




预测性维护：利用MATLAB提取 状态指示器

什么是状态指示器？


预测性维护算法开发的关键一步是识别 *状态指示器*：即随着系统性能下降其数值以可预测的方式发生变化的特征。状态指示器可帮助您区分正常运行和故障运行。从预处理的系统数据中提取状态指示器，然后使用它们进行故障分类及预估剩余寿命 (RUL)。



视觉操作练习

首先开展视觉操作练习,了解状态指示器的如何工作。这两种形状有什么区别?

圆形



二者之间似乎不存在显著区别,因为这两个圆形看起来几乎一模一样。


视觉操作练习 - 续

上一页的两个形状看似完全相同,这是因为我们从顶视图这个特定角度进行观察。但是,如果换个角度,可清楚地看到两个形状的区别。我们发现,一个是圆锥体,而另一个是圆柱体。

圆锥体



圆柱体



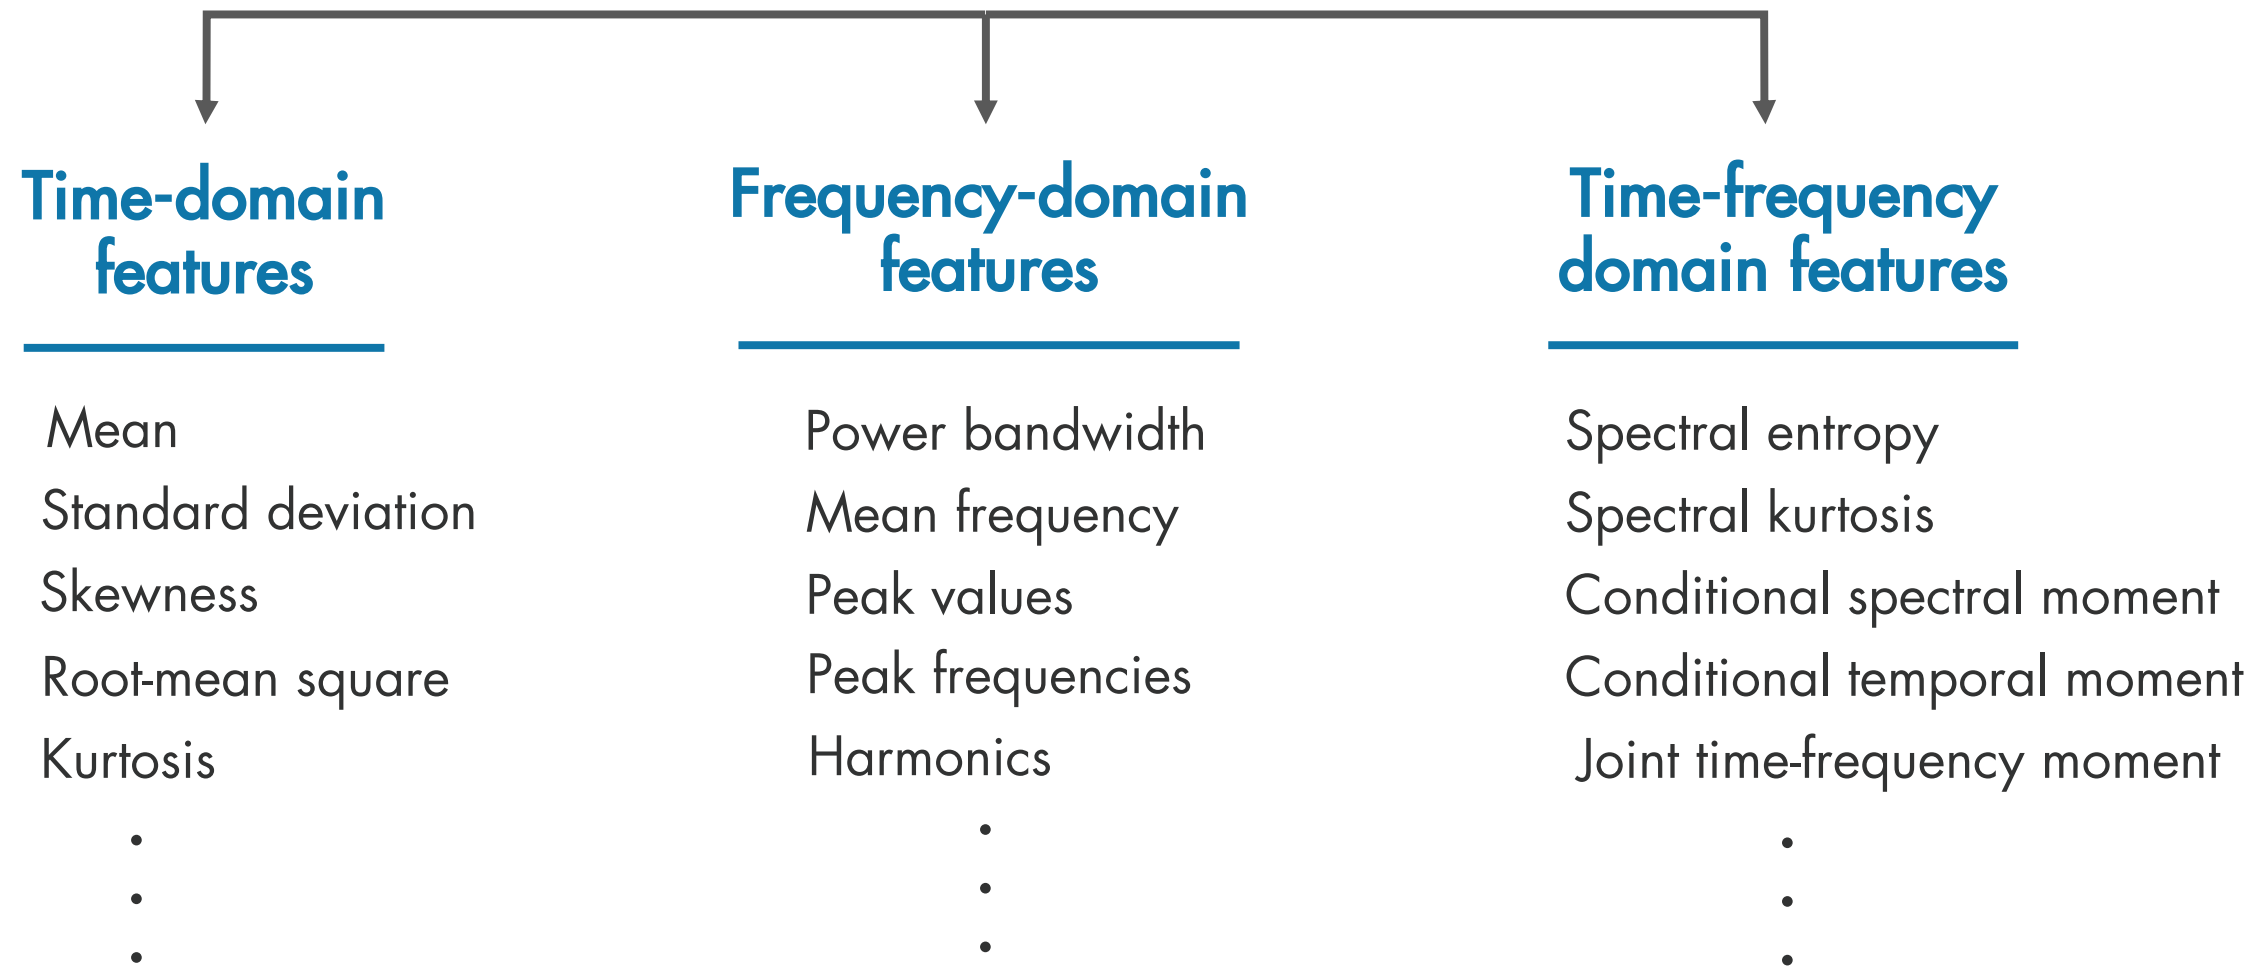
同样,从机器的角度观察原始测量数据很难区分正常运行和故障运行。然而,使用状态指示器则可从不同的角度观察数据,帮助您区分正常运行和故障运行。



使用基于信号的方法提取特征

您可以使用时域、频域和时频域特征从数据中提取出状态指示器：


Signal-Based Condition Indicators



使用基于信号的方法提取特征 - 续


时域特征

在某些系统中, 简单的时间信号统计特征即可充当状态指示器, 区分正常状态和故障状态。例如, 随着系统性能下降, 某一特定信号或其标准差变化的平均值可能发生变化。您也可以使用信号的高阶矩, 如偏度和峰度。可以利用这些特征确定区分正常运行和故障运行的阈值, 或者查找标记系统状态变化的值突变。



时域振动信号变化趋势表明风力涡轮机高速轴性能退化连续超过 50 天。

Predictive Maintenance Toolbox™ 是 MATLAB® 的一款附加产品, 其中包含用于计算时域特征的其他函数, 如 [涡轮机高速轴承预测](#) 示例所示。



单调性图显示不同时域和频域特征的特征重要性排名。

使用基于信号的方法提取特征 - 续

频域特征




有时, 单纯使用时域特征不足以充当状态指示器, 因此还要查看频域特征。

获取一台包含旋转组件和三大振动源(轴承、电机轴和盘)的机器。如果仔细观察时域中的机器振动数据, 将可了解这些不同旋转组件产生的所

有振动的综合效果。但是, 您可以通过分析频域数据隔离不同的振动源, 如第二幅图所示。峰值幅度以及它与标称值之间的差值可指示故障严重性。

有关计算频域状态指示器的更多信息, 请访问 [使用振动信号进行状态监控和预测](#) 示例。

Machine with rotating components



分析时域中的机器振动数据时, 轴承、电机轴和盘都会对振幅有所影响。
您可以通过频域分析区分不同的振动源。


使用基于信号的方法提取特征 - 续

时频域特性

另一种特征提取方法是对数据执行时频谱分析,这有助于描述一段时间的信号频谱内容变化。时频域状态指示器涵盖多种特征,如谱峰度和谱熵。

*滚动元件轴承故障*示例显示如何使用峰度图、谱峰度和包络谱确定不同类型的滚动元件轴承故障。

» *了解关于时域、频域和时频域特征的更多信息*



直方图显示了三种轴承状态的明确区别。带通频率的内外圈振幅对数比是对轴承故障进行分类的一项有效特征。

预测性维护工作流程

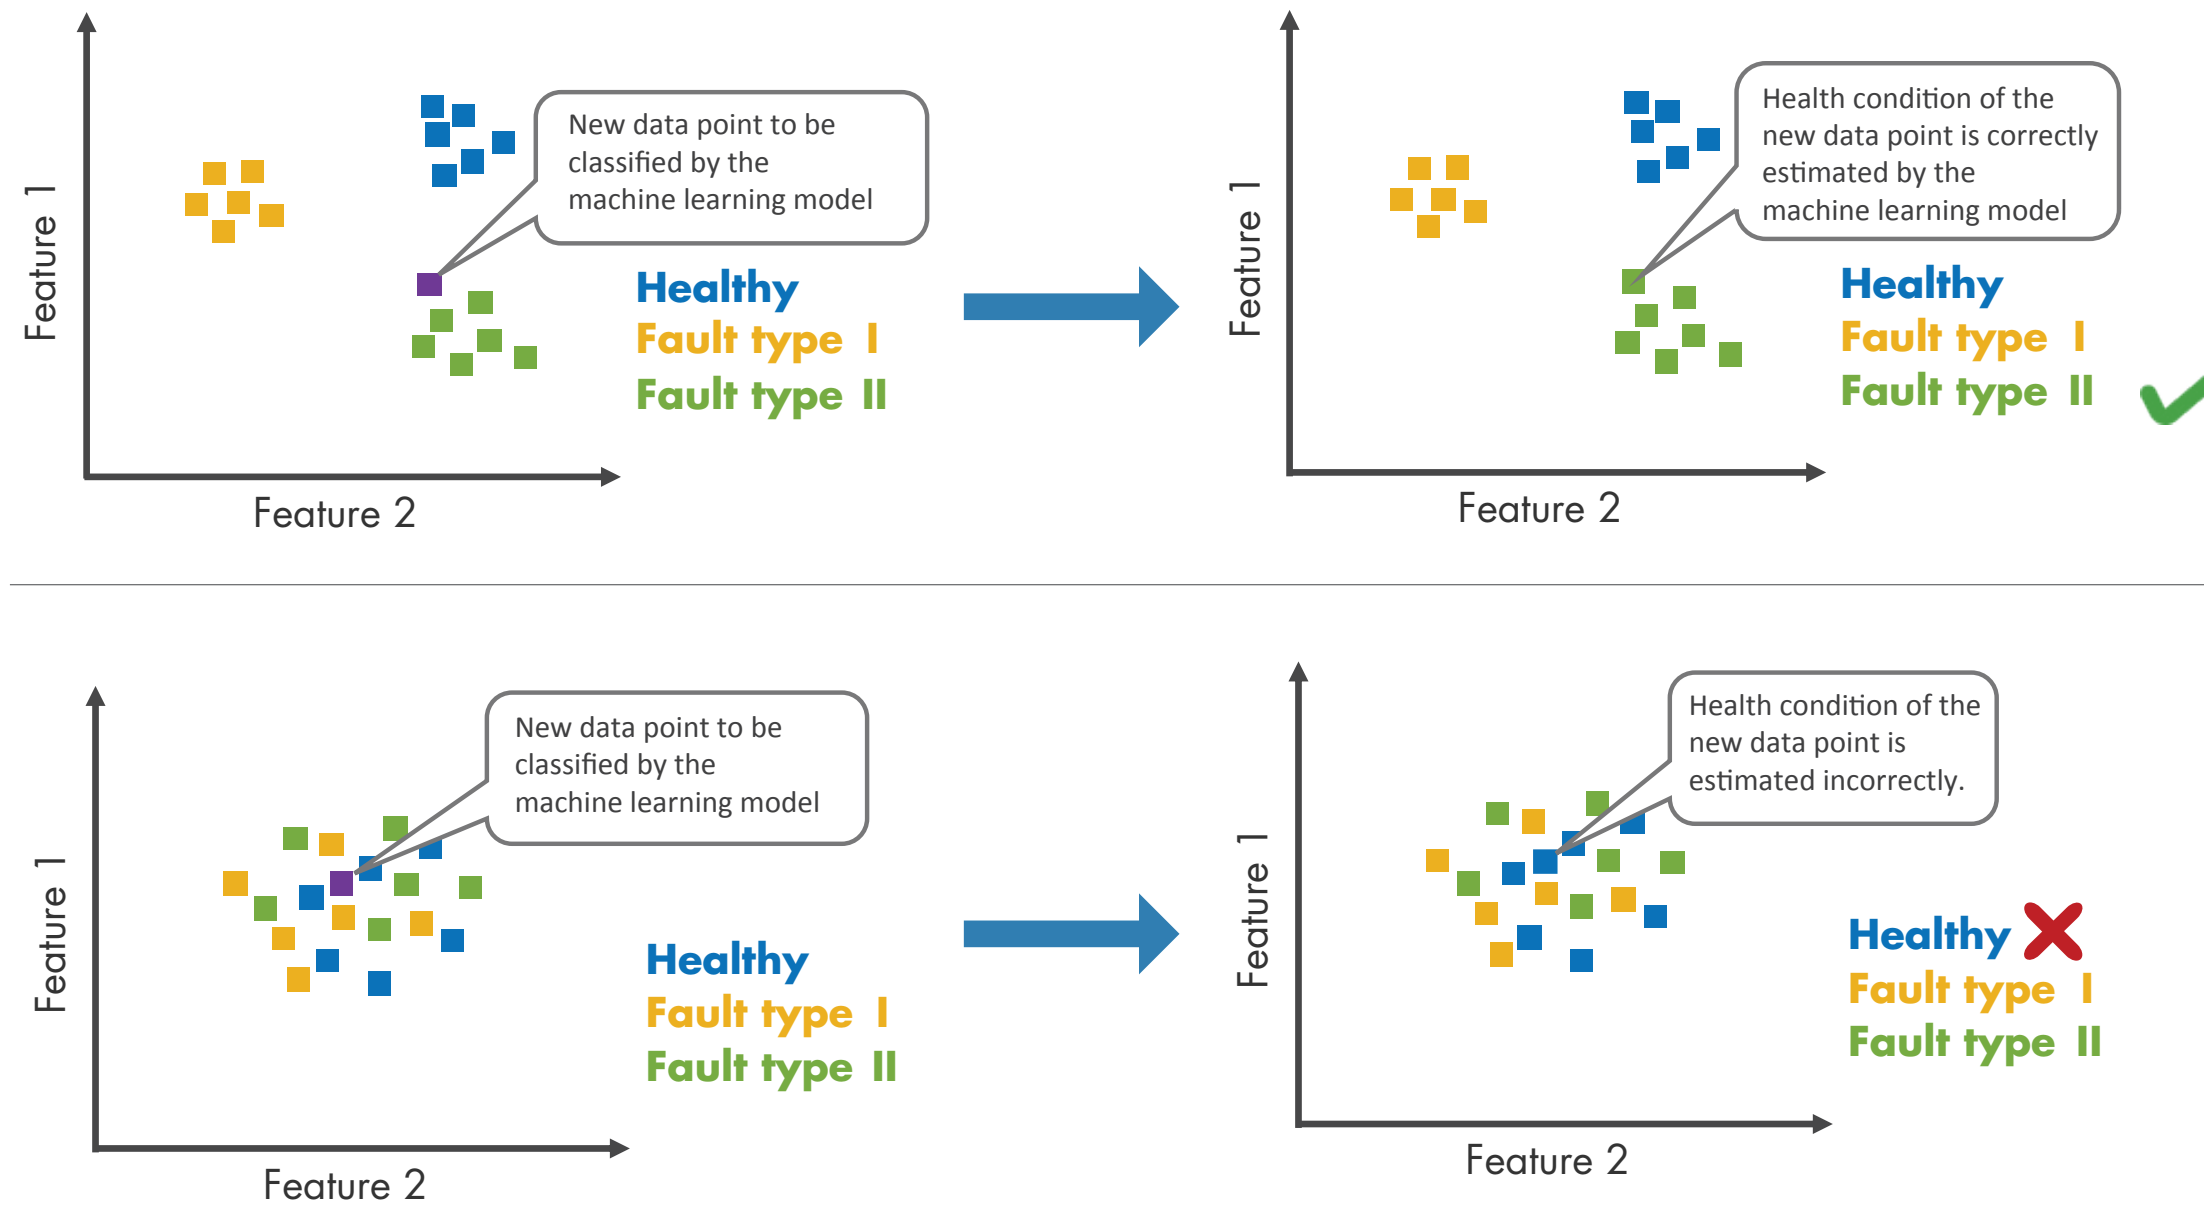
现在您已对状态指示器有所认识,是时候开始介绍提取用于识别状态指示器的特征所涉及的步骤了。设计预测性维护算法,首先需要收集机器在不同工况和故障状态下生成的数据。然后,预处理原始数据,将其清理并转换为特定形式,以便从中提取状态指示器。提取特征,寻找独特特征,意味着这些特征可以对正常运行和不同故障类型做出唯一的定义。这些特征将成为您的 *状态指示器*。

您可以使用提取的特征来训练机器学习模型,以便进行故障分类及预估剩余寿命。接着,还可以部署算法并将其集成到您的系统中,以用于机器监控和维护。



什么是独特特征?为什么独特特征很重要?


确定某些有用特征后,您可以使用这些特征训练机器学习模型。如果所选的特征集是独特特征集,将新的机器数据馈送给模型时,模型可以正确估计机器的当前状态。



示例：三缸泵

本示例使用三缸泵演示工作流程。泵内装有电机，用于转动曲轴，继而驱动三个柱塞。流体将被吸进出口，再从出口排出，届时需使用传感器测量压力。此类泵中可能发生的故障包括：

- 密封件泄漏
- 入口堵塞
- 轴承磨损

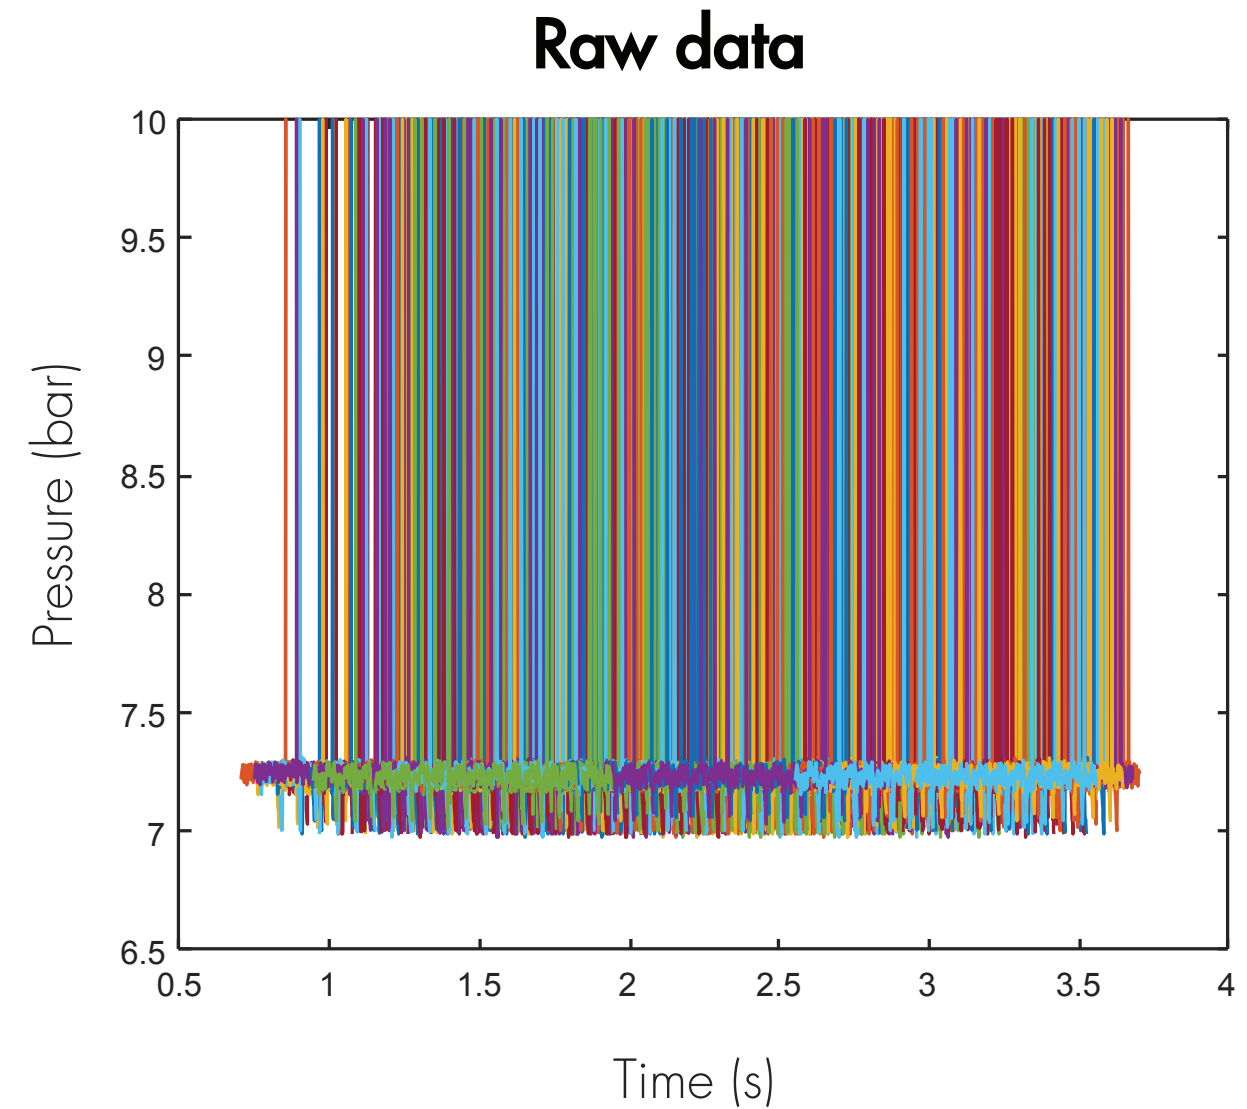


采集数据



压力数据包括在正常运行的稳定状态下提取的一秒钟测量数据、全部三种故障及其组合：

- 正常运行
- 入口堵塞
- 轴承磨损
- 密封件泄漏
- 入口堵塞、轴承磨损
- 密封件泄漏、轴承磨损
- 密封件泄漏、入口堵塞

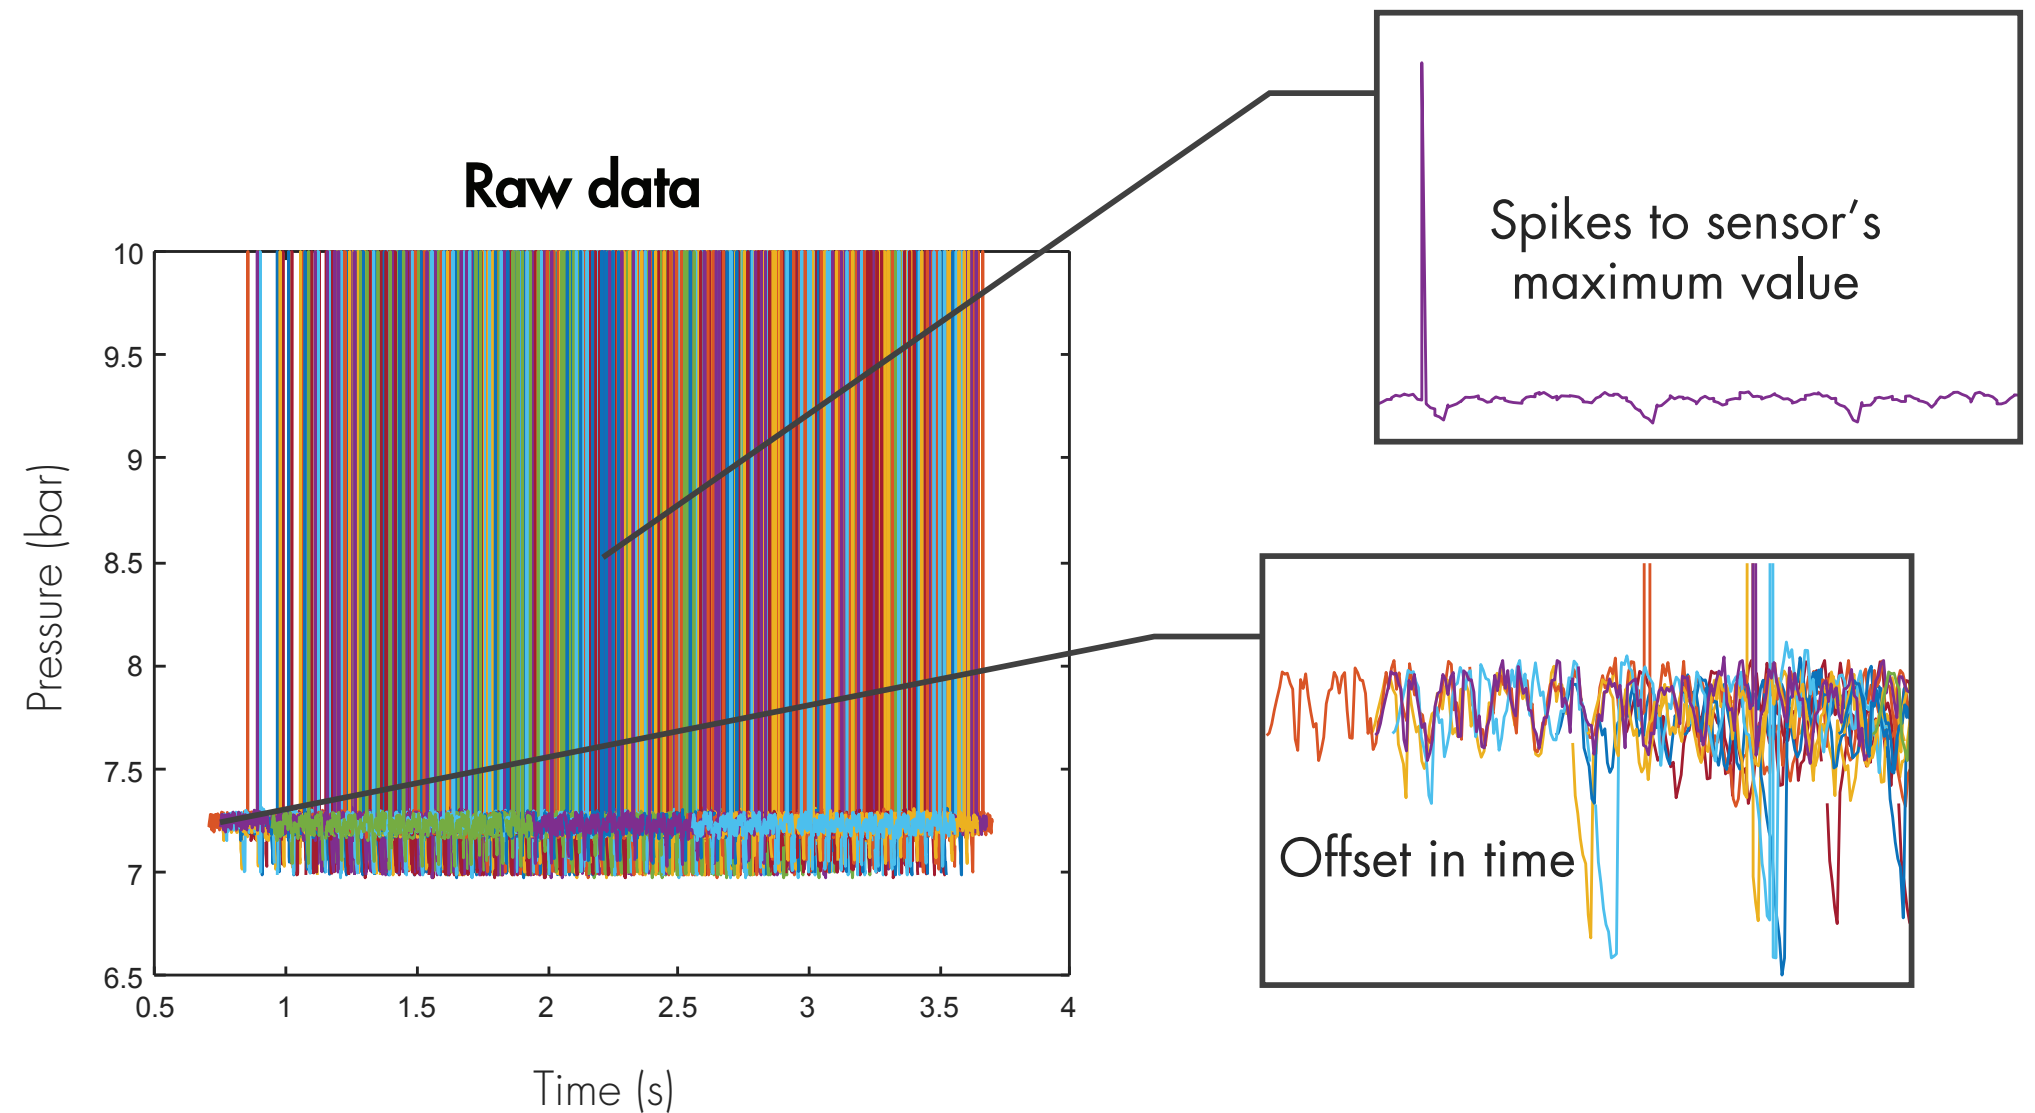


从三缸泵收集的压力数据图。

预处理数据




您需要将数据转换为可用格式，以提取状态指示器。原始数据含有噪声，而且尖峰达到传感器的最大值。即使测量持续时间相同，也会发生时间偏移。



预处理数据 - 续

MATLAB 提供了大量函数, 帮助平滑、去噪及对信号数据执行其他预处理技术。

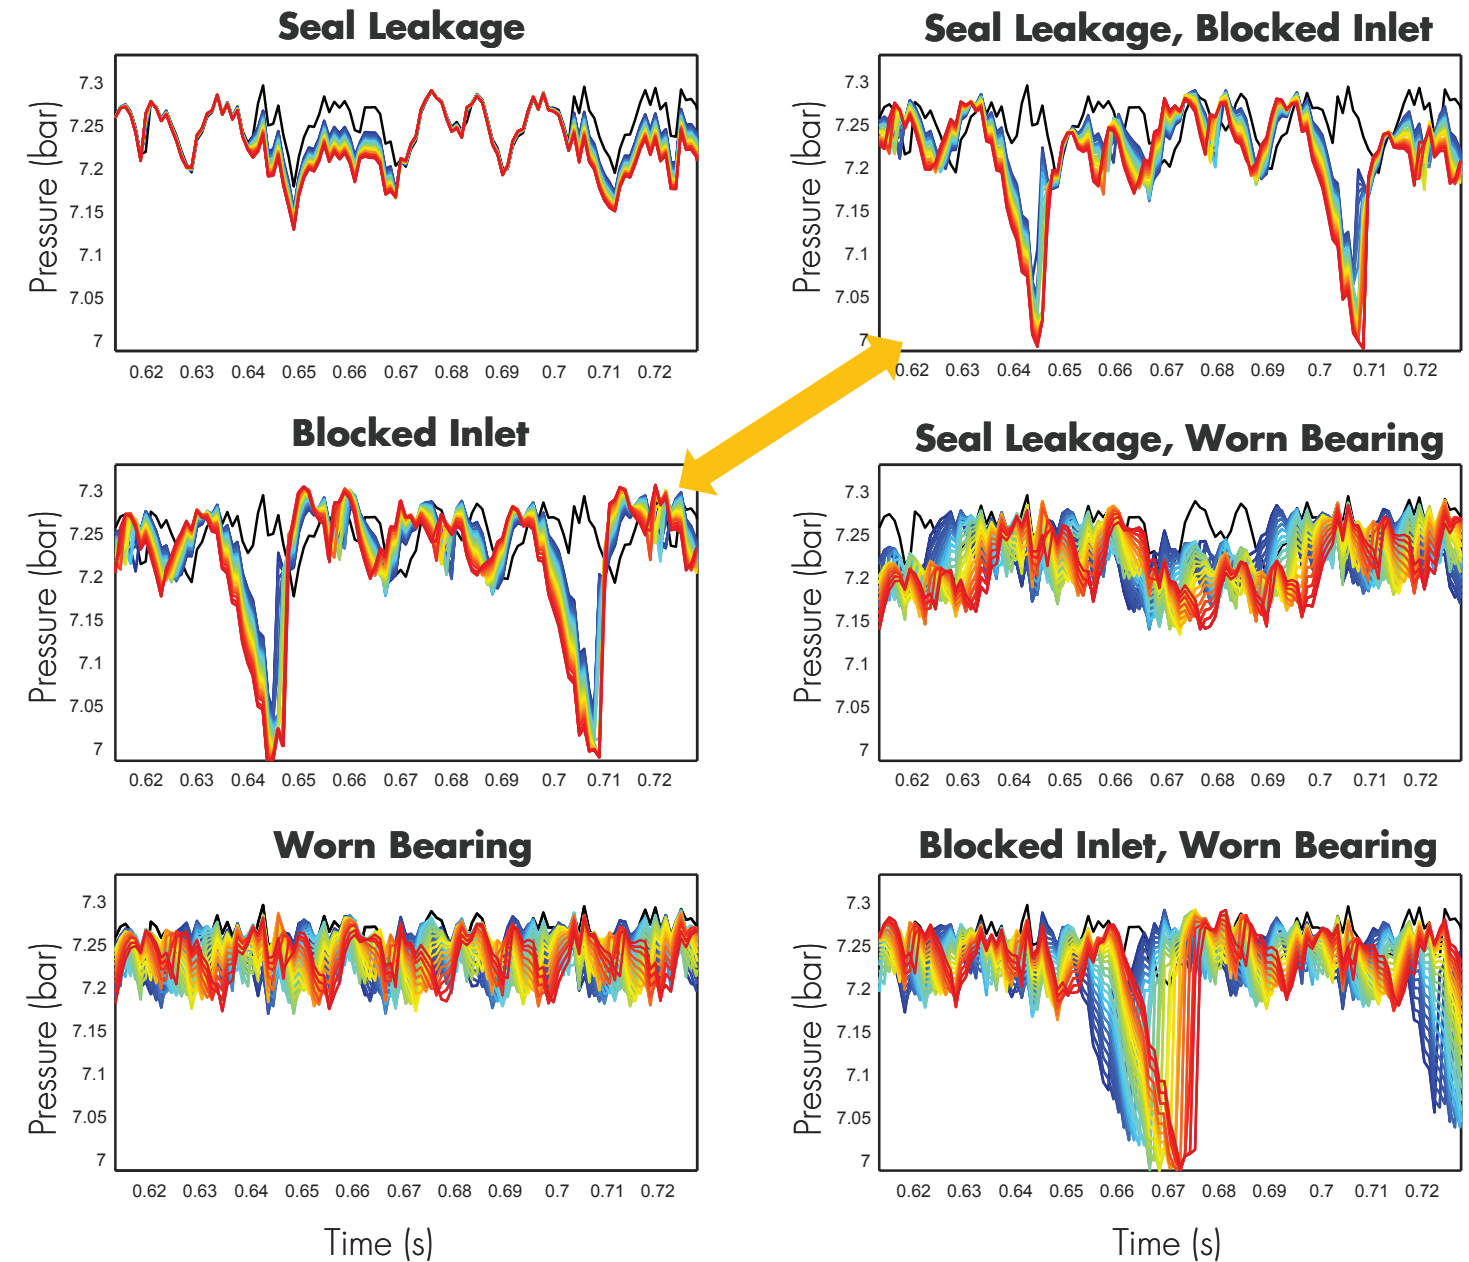

经过处理的数据包括所有正常状态和故障状态。为针对不同的故障开展调查, 您可以单独进行绘图。首先要注意这些图上的时域压力信号的周期性行为。其次, 查看下一页的短时间绘图, 更清晰地掌握每个周期的具体情况。



预处理数据 - 续

这些图更详细地展示了不同类型故障的压力信号。泵退化引发的压力数据变化会导致颜色改变,从深蓝色变为红色表明故障严重性加剧。现在的问题是:您能否区分每个图上的黑色线条(正常运行)与其余数据?能否确定每组彩色线条之间的独特差异?注意,“密封件泄漏、入口堵塞”与“入口堵塞”故障的压力数据看上去很相似。

现在,我们来介绍一些用于确定状态指示器的时域特征,从而帮助您区分故障类型。




使用时域特征确定状态指示器



通过反复试验了解下列各个通用时域特征集的执行情况：[平均值](#)、[方差](#)、[偏度](#)和[峰度](#)。

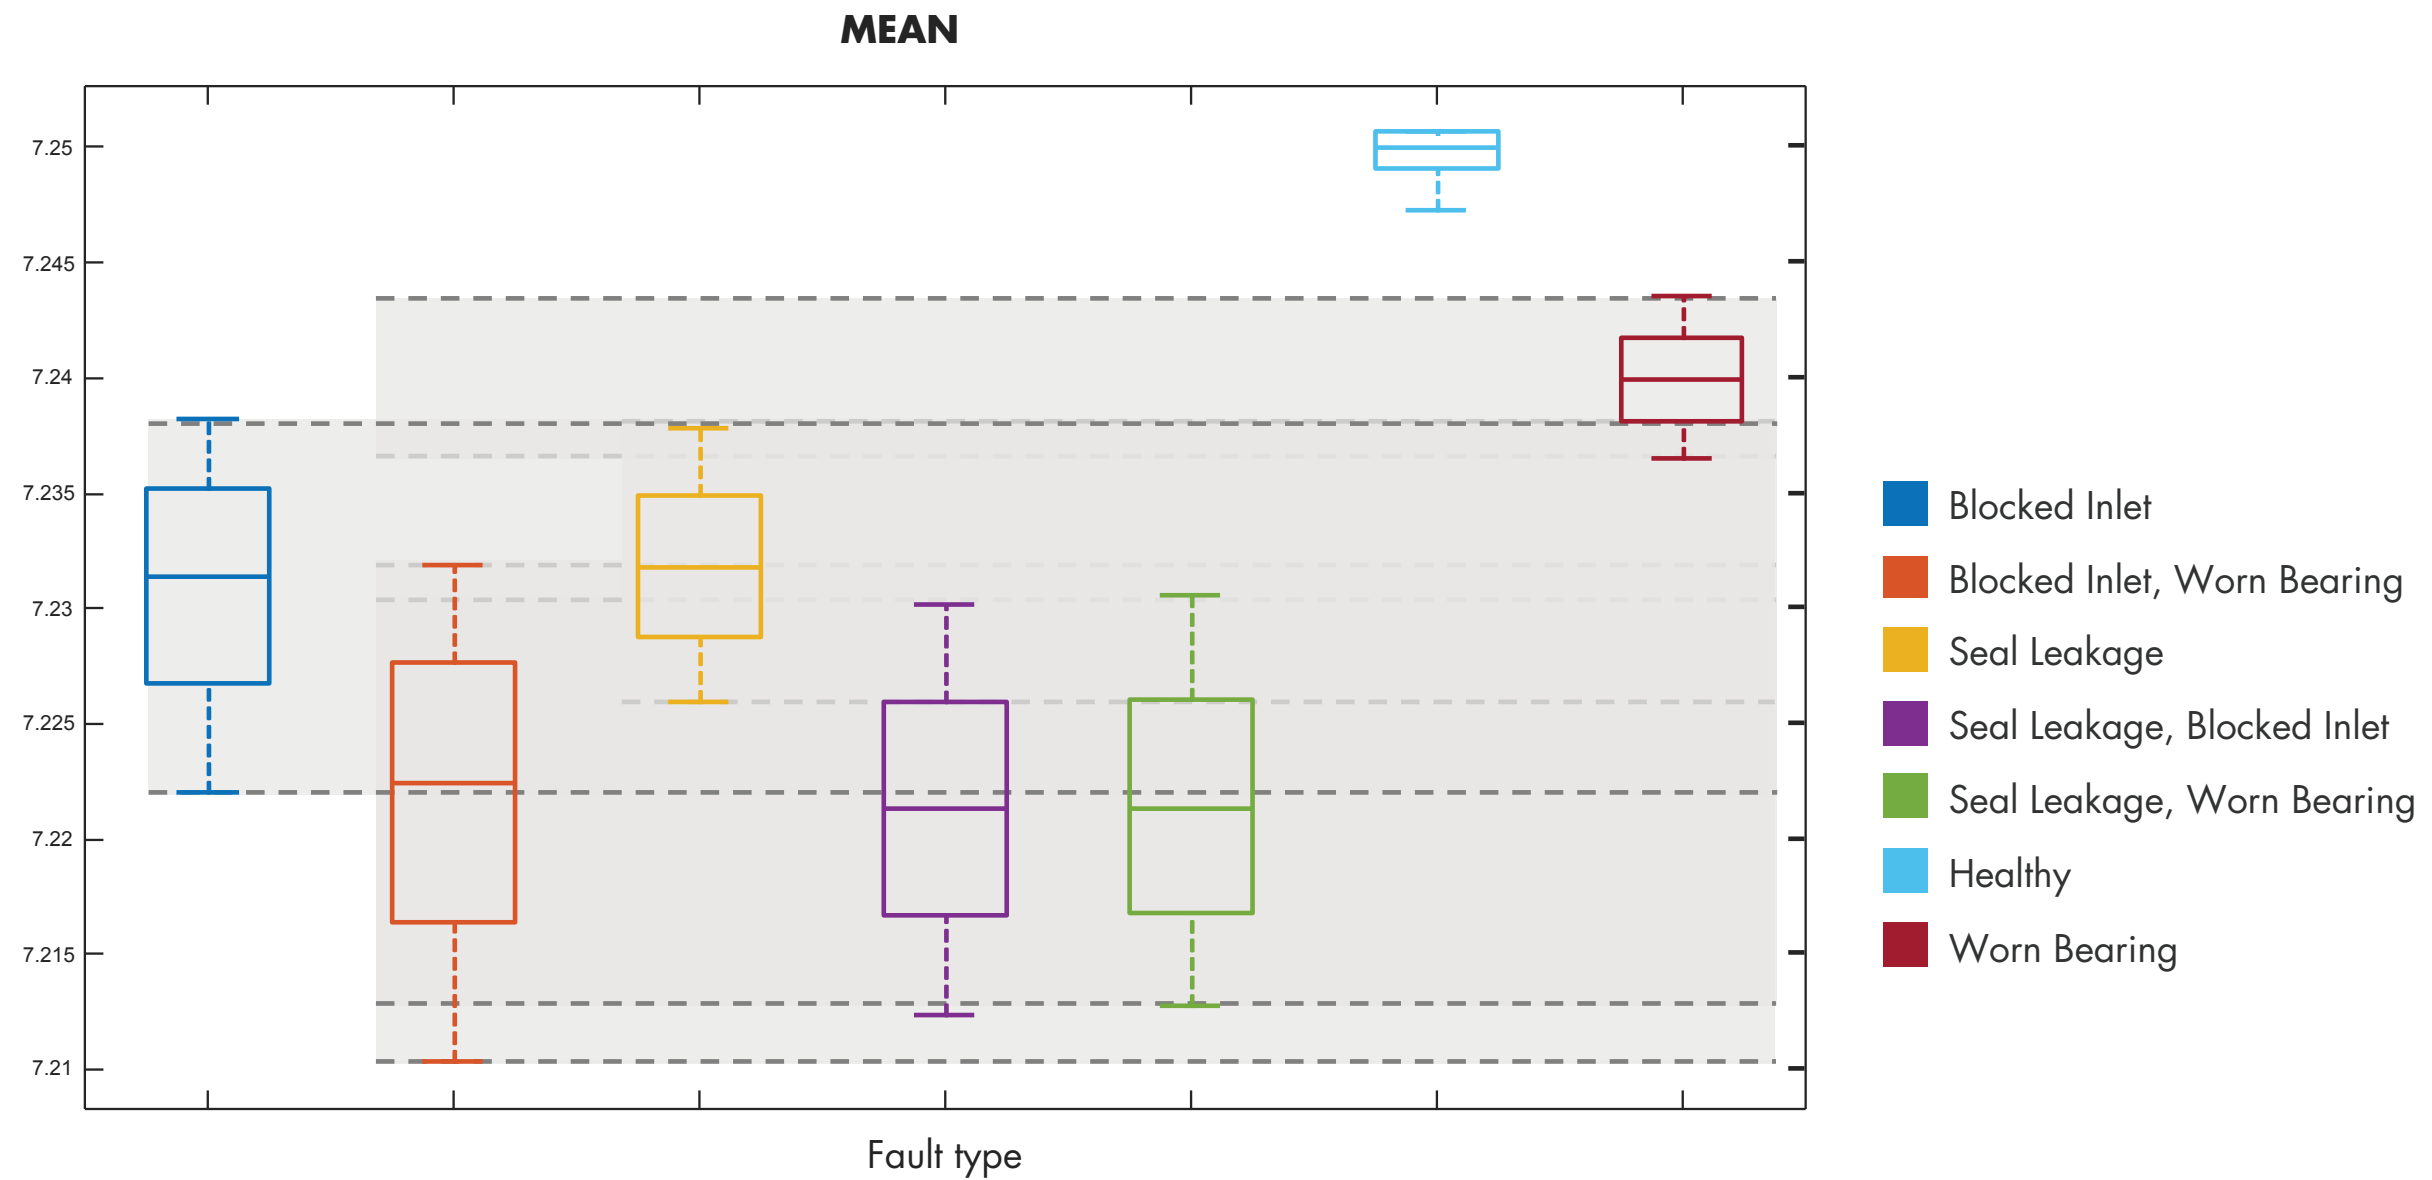
了解这些状态指示器能否区分故障类型的一种方法是使用箱形图开展调查。首先，针对正常状态和入口堵塞故障绘制单一特征，如平均值。

绘图中的方框不重叠。意味着，这些数据组之间存在差异。您可以使用压力数据平均值轻松区分入口堵塞故障与正常状态。







使用时域特征确定状态指示器 - 续

当添加其他故障类型数据集时,情况也会发生转变。您无法区分所有故障类型,因为其中一些故障类型存在重叠。由于这种重叠现象,其自身的平均值不足以区分故障类型。



使用时域特征确定状态指示器 - 续

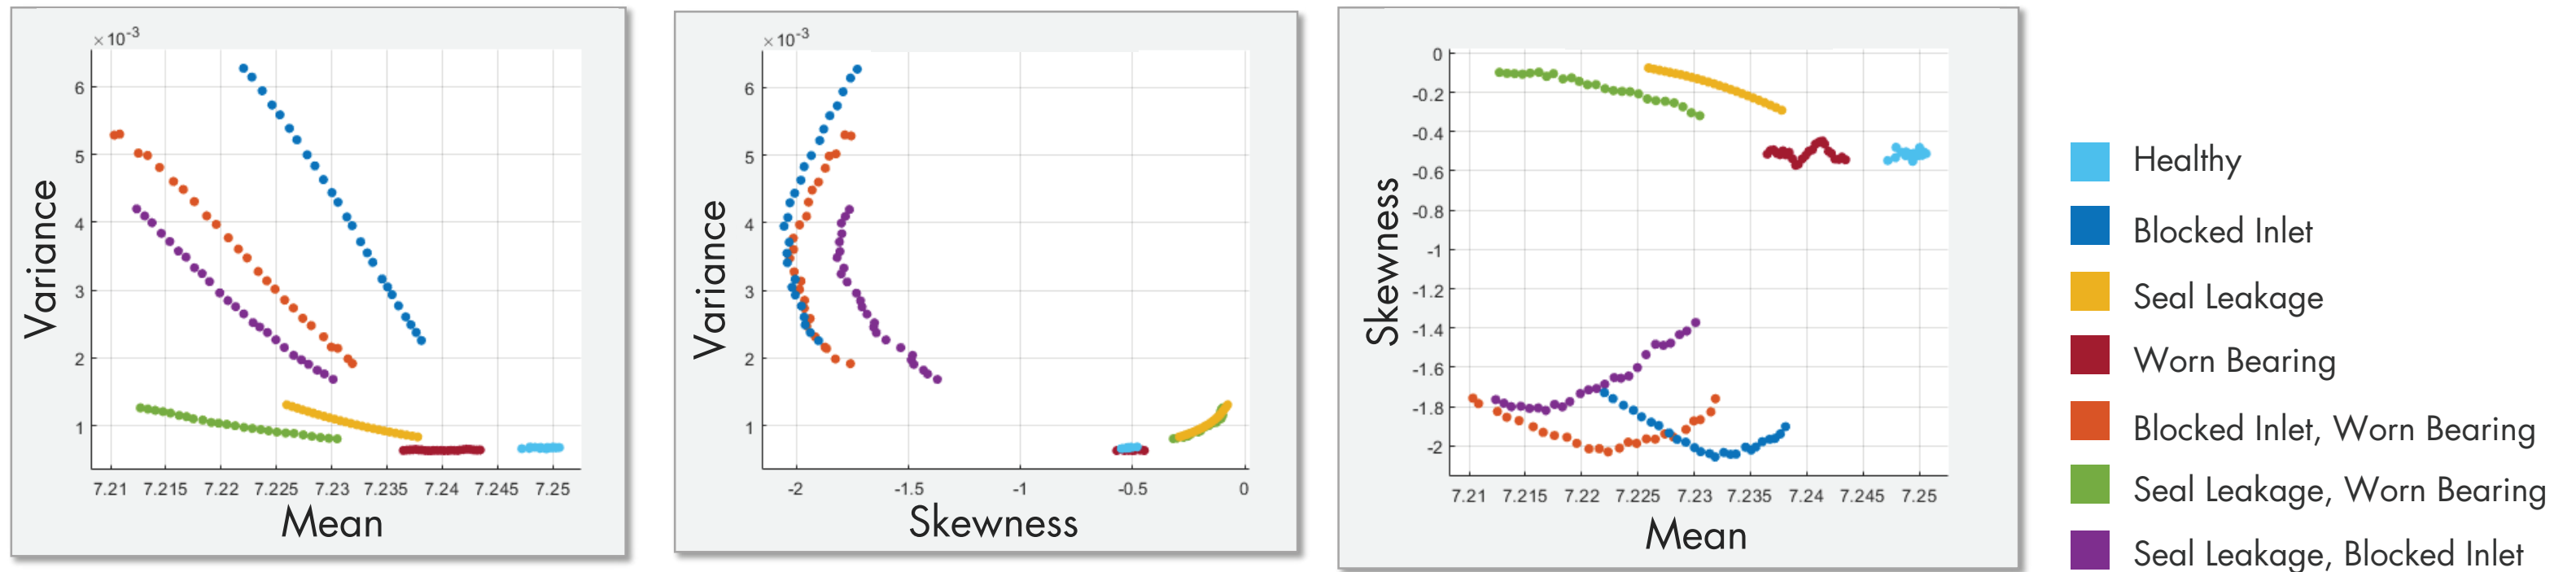
哪怕尝试使用其他特征执行此操作, 也将得出相同的结论: 单一状态指示器不足以对故障行为进行分类, 尤其是存在多种故障的情况下。



- Blocked Inlet
- Blocked Inlet, Worn Bearing
- Seal Leakage
- Seal Leakage, Blocked Inlet
- Seal Leakage, Worn Bearing
- Healthy
- Worn Bearing

使用时域特征确定状态指示器 - 续

下面是特征组合散点图:平均值、方差和偏度。注意方差与平均值图对不同故障类型的区分效果。



您会立刻发现两个状态指示器区分不同故障的效果优于一个状态指示器。您可以尝试不同的特征对,确定哪些特征对的故障分类效果更好。

使用时域特征确定状态指示器 - 续

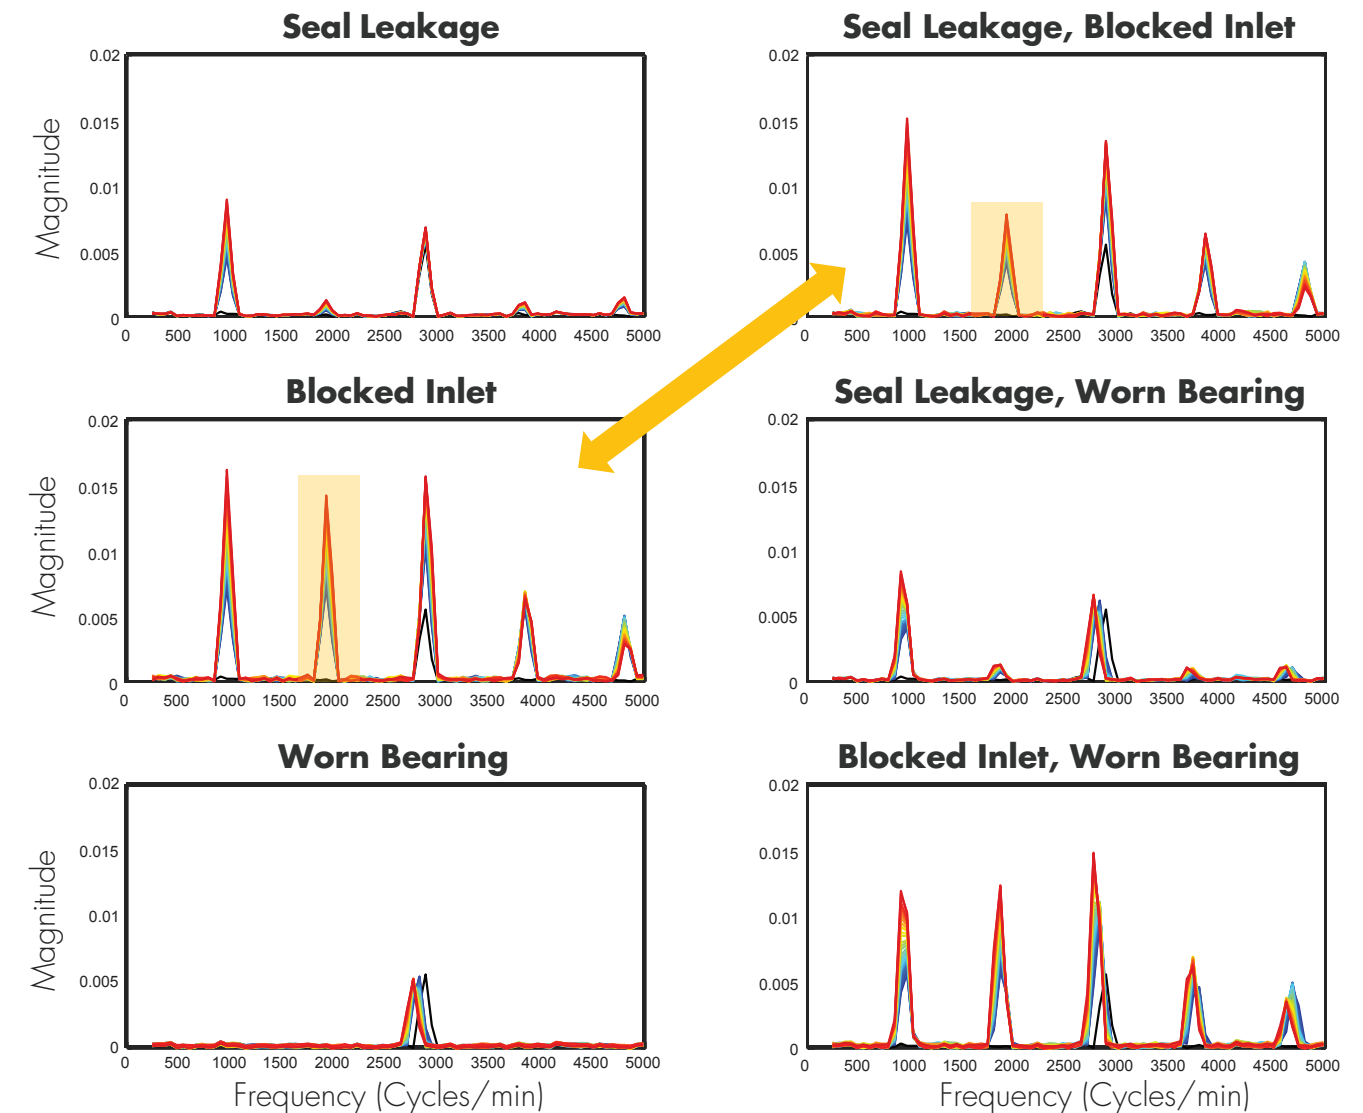
频域分析对于分析周期数据及从装有旋转组件的机器采集的数据很重要;让我们看看能否通过分析频域数据来提取其他特征。

这些图相互之间的峰值和峰值频率有所不同,因而可将它们作为状态指示器。由于数据集相似,很难使用时域特征区分“密封件泄漏、入口堵塞”与“入口堵塞”故障。仔细观察频域数据,您可以看到突出显示的频率范围的峰值,这将有助于您成功区分这两种故障。

在 MATLAB 中,您可以使用 `fft` 函数计算信号的快速傅立叶变换并在频域中进行分析。然后,可以使用 `findpeaks` 函数从 FFT 信号中提取峰值和峰值频率。

总之,在本示例中,应使用以下特征训练机器学习模型:


- **时域特征:**平均值、方差、偏度和峰度
- **频域特征:**峰值和峰值频率



使用时域特征确定状态指示器 - 续

选择频域特征后, 尝试执行类似于时域特征采用的分析。下图显示了彼此相对的第二个和第五个峰值。

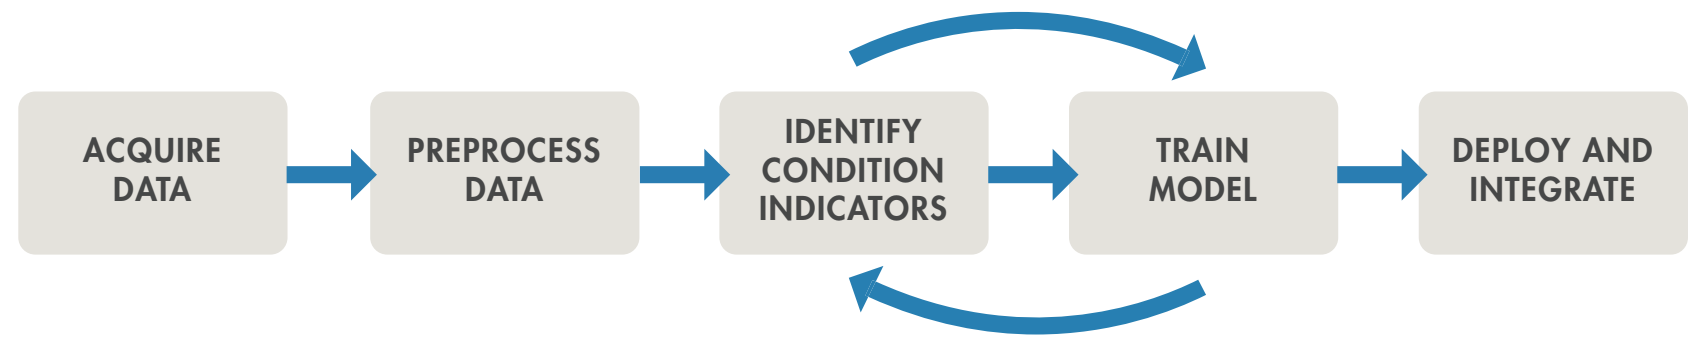
这些特征可有效区分不同的组并用黄色圆形突出显示。这意味着, 所选特征是独特特征, 也是训练机器学习模型的良好候选特征。



请注意, 当您对这些特征开展调查时, 不仅要查找不同的集群, 还要保证它们远离彼此。这样更便于训练模型确定新的数据点。

上一页显示每种故障的峰值图, 彩色标记故障, 黑色标记正常状态。请注意, “轴承磨损”图仅包含轴承磨损和正常状态的峰值 3。因此, 峰值 2 和峰值 5 的显示图中未显示这些状态。这是我们需要利用多个特征有效区分不同组的另一原因。

训练模型

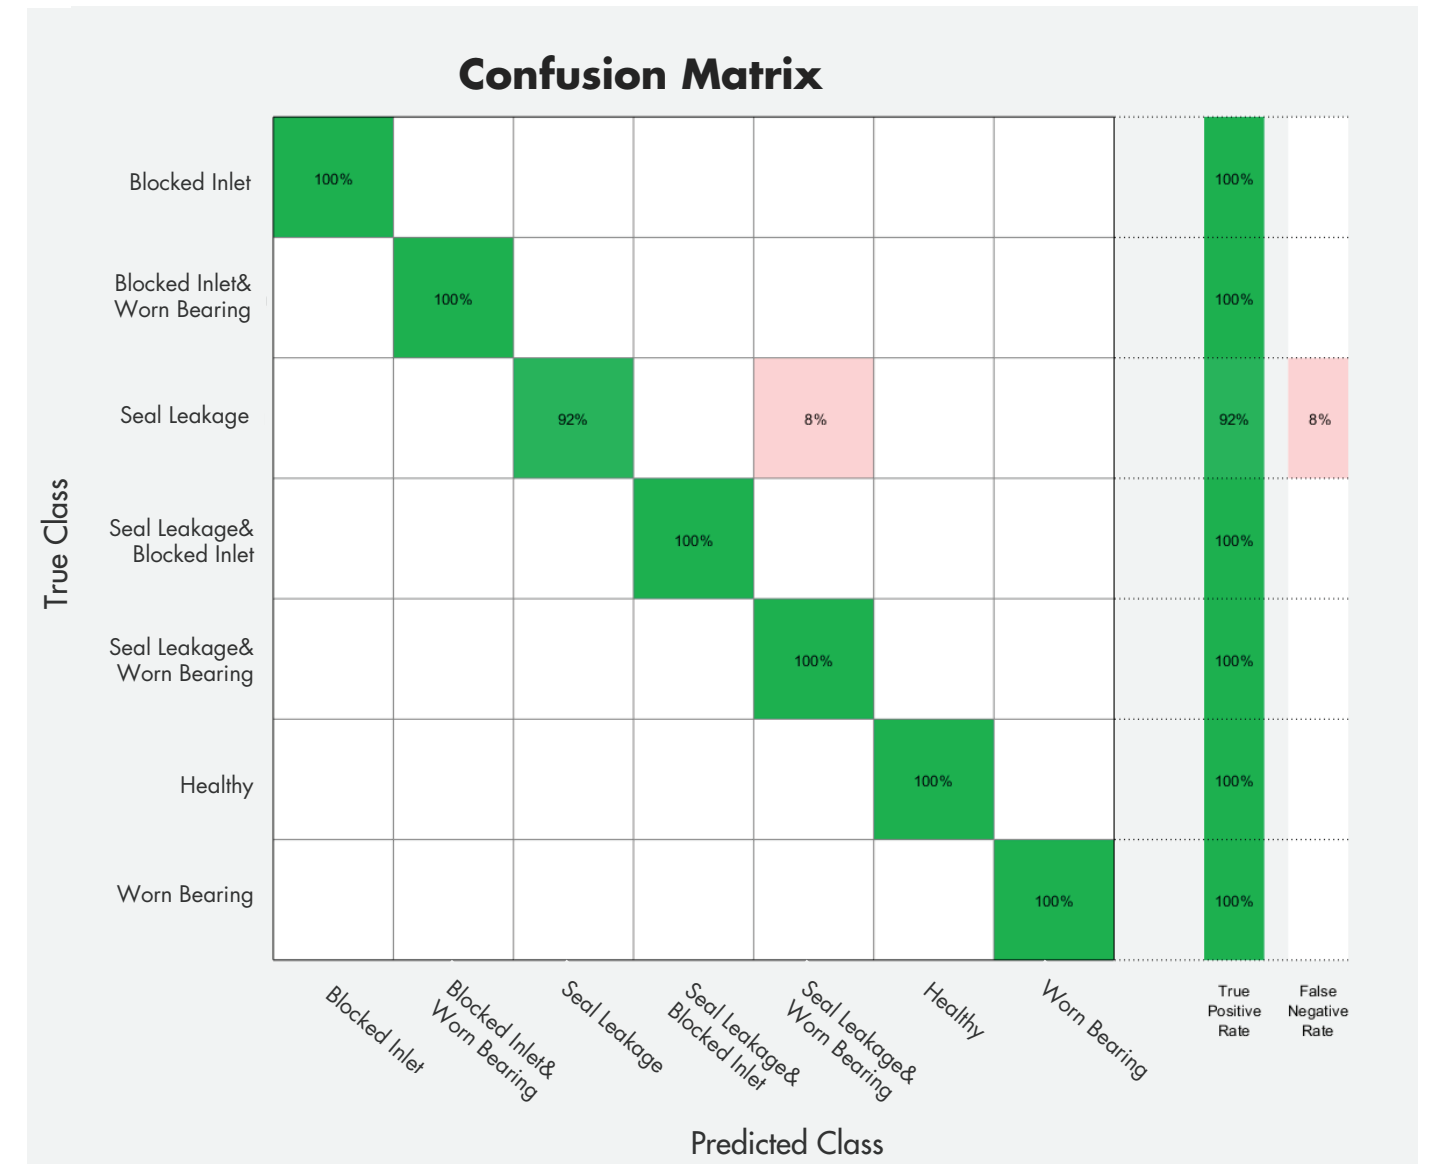


提取状态指示器后,您可以使用提取的状态指示器(作为特征)训练机器学习模型,并使用混淆矩阵检查训练模型的准确度。右侧的混淆矩阵显示训练后的表现最佳的分类器之一的结果。MATLAB [分类学习器应用程序](#)可快速帮助您确定最适合您数据集的分类器。

在本图中,绿色代表真阳性(true positive)率,红色代表假阴性(false negative)率。

如果您对机器学习模型的准确度感到满意,则可继续部署预测性维护算法并将其集成至系统。否则,应重新审视预测性维护工作流程的特征提取步骤,尝试使用不同的特征集训练机器学习模型,如工作流程图中的箭头所示。

您可能想知道,究竟需要多少个特征才足以训练机器学习模型?很遗憾,并不存在所谓的具体数量。请记住,机器学习模型可以从高维度独特特征集中获益,也可以有效区分故障类型。



了解更多

观看

[预测性维护技术讲座 - 视频系列](#)

[使用 MATLAB 和 Simulink 进行预测性维护 \(35:54\) - 视频](#)

[使用 Diagnostic Feature Designer 应用程序提取特征 \(4:45\) - 视频](#)

阅读

[克服预测性维护的四个常见障碍 - 白皮书](#)

深入了解

[使用 MATLAB 进行预测性维护 - 代码示例](#)

[Predictive Maintenance Toolbox - 概述](#)

[» 试用 Predictive Maintenance Toolbox](#)