

机器学习模型

让IT服务管理从被动响应转向主动出击

✦ 探索无代码机器学习如何帮助服务台团队预测、预防及高效运营

目录

■ 引言	3
■ 精准预测，化解升级风险	4
■ 提前预判变更带来的影响	9
■ 借助机器学习实现资产健康的主动维护	14
■ 借助定制化预测平衡分布式基础设施容量	17
■ 结语	24
■ 关于 ManageEngine Analytics Plus	25

引言

试想一下，倘若您在繁忙的城市道路或跨越乡野长途驾驶，但只能参考一张老旧的纸质地图——既看不到道路封闭、交通拥堵的信息，也看不到恶劣天气的预警，那就有可能在最不合时宜的时刻抛锚、迟到或被迫绕行。

这正是当今复杂的 IT 服务管理（ITSM）环境中，仅依赖传统分析手段的真实写照。常用的旧版报表和仪表盘固然有助于我们了解“发生了什么”，却难以回答一个更有价值的问题：“接下来会发生什么？”于是越来越多的 IT 领导者开始借助机器学习（ML），不仅用它回顾过去，更用它预测未来、防患于未然，并以智能化、数据驱动的策略未雨绸缪。



SAP LeanIX 最新调查显示^[1]

90%的 IT 专家认为，清晰掌握组织中的 AI 使用情况十分重要。

本文将探讨机器学习如何为传统 IT 分析赋能，使其从被动的报表工具转变为主动的战略优势，并深入剖析四个高价值应用场景，展示 IT 团队如何借助机器学习驱动的分析走在前列。

精准预测，化解升级风险

在如今瞬息万变的 IT 环境中，事件管理常常让人感觉像是在不断“追赶”的游戏。大多数组织都陷入了一个被动循环：工单如潮水般涌入，部分得到解决，但仍有相当数量的工单会升级、突破 SLA(服务水平协议)，在严重情况下甚至会影响核心系统——而这一切往往要等到问题发生后才会被处理。

IT 团队往往只能在问题发生之后被动应对。这种被动的应对方式不仅效率低下，更已成为一种根深蒂固的工作模式，由此带来：

- 高峰期团队人手不足
- 在季度末或产品发布等可预见的时间节点，升级事件集中爆发
- 即使是经验丰富的团队，也会一再遭遇 SLA 违约的意外事件
- **管理层总会遇到那个无法避免的问题：“我们为什么没能提前发现？”**

许多 IT 团队将自动化工单处理视为一种高性价比的解决方案。这类系统通常通过分析历史事件或解决方案数据，来调整工作流程、指派工单并辅助问题解决。然而，即便是成熟的 ITSM 体系，尽管已经实现了自动化，依然高度依赖历史报表。这些仪表盘和报表虽然有助于理解过去的表现，却只能描述“已经发生”的事情。

仅靠静态仪表盘，IT 领导者无法：

- 提前预警下一次关键事件高峰的出现
- 告知服务台经理团队未来几天是否会出现不堪重负的事件发生
- 展示季节性工作负载，人员变动或基础设施维护等多种因素如何共同提高升级风险但实际上这些事都是能够做到的——只要在正确的时机运用机器学习驱动的预测能力。

拥抱机器学习驱动的多变量预测

IT 领导者真正需要的，不仅仅是历史仪表盘，而是一套能够做到以下几点精密解决方案：


- 识别隐藏在 IT 数据深处的关联，涵盖时间、部门和服务类别等多个维度
- 从这些复杂数据中识别潜在规律
- 基于这些规律推演未来的需求与场景
- 让团队能够在问题累积、升级并导致 SLA 违约之前，主动采取行动

这正是机器学习驱动的多变量预测重要之处——这是一种专为企业 IT 这种混乱且不断演变的环境量身打造的预测技术。将先进的多变量预测应用于服务台、资产管理和 IT 运维，可以帮助 IT 团队将原始指标转化为精准的事件预测，推动团队从静态报表真正转向预测性事件管理。

与只孤立看待单一数值的传统方法不同，多变量预测能够理解多种因素如何相互作用、共同影响结果。通过分析这些相互关联的变量，它让 ITSM 具备风险感知能力，真正实现主动管理。

以某全球化 ITSM 团队为例，该团队每月都会反复面临升级事件激增的困扰。尽管定期调整了人员配置，但随着事件请求量不断上升，SLA 违约和后续升级事件也随之增多。

如果 IT 经理仅依靠历史数据来预测未来几个月的升级趋势，那么预测结果将呈现出与事件量同步上升的线性增长——如下方分析所示。




这种片面的视角，会导致人员调配、知识库文章准备、告警配置等应对策略，都建立在信息不充分的猜测之上。结果呢？

- 有些周准备过度，有些周又准备不足
- 错失隐藏在多重趋势叠加之下的早期的预警信号

然而，借助机器学习驱动的多变量预测，IT 领导者就能够将众多影响升级事件量的因素一并纳入考量。

例如，同样的分析在采用线性方法时，预测的是事件量与升级量之间的线性关系；

但一旦引入多变量预测就会发现：即便在 11 月、12 月这样事件量高企的月份，升级事件数量实际上依然保持在低位。相反，9 月尽管事件量较低，升级事件数量却被预测会高于平均水平。



这项分析清楚地表明，除了事件量本身之外，还有许多其他因素在显著影响着升级事件的发生，包括：

- **首次响应延迟：**响应时间越长，小问题也可能被放大
- **特定部门上报的事件：**某些部门可能面临独特挑战或更高的紧急程度
- **年度结算或法定节假日等事件：**可能影响资源可用性和任务指派，从而引发意外的事件高峰

唯有多变量预测，才能将这些彼此关联却又各不相同的因素综合起来，给出真正有意义的升级预测。

更重要的是，它能为 IT 团队提供切实可行的洞察，帮助其精准定位应对策略、降低每月升级事件量。

02

提前预判变更带来的影响

变更是任何组织 IT 环境中不可避免、也不可或缺的一部分。无论是新产品上线、系统更新、补丁部署、基础设施扩容，还是看似微小的策略调整，这些通常都需要通过服务台内结构化的变更工作流程来管理。

然而，大规模变更往往会带来意料之外的结果，从小故障到严重的系统中断，不一而足：

- 新补丁引发的意外停机
- 配置更新导致的工作流故障
- 基础设施迁移后出现应用程序故障或性能下降
- 变更相关工单量激增，令服务台不堪重负。由于任何变更场景都可能会偏离常规的预期工作流，IT 团队必须做好充分准备。目前，IT 团队大多依靠过往经验、直觉判断或模拟演练来预测变更的结果或影响。这些方法虽然能提供一定参考，但对于即将到来的具体 IT 场景而言，往往不够准确或全面。

真正理想的解决方案，是在变更真正部署之前，就能提前预测该变更对目标服务实时性能或预期结果可能产生的影响。

要实现这种预见能力，IT 团队可以先借助无代码机器学习构建工具，搭建一个定制化的“变更影响评分模型”。这一强大的模型基于组织自身的变更管理数据进行训练，能够自动量化每一项拟议变更的预期风险与影响程度。

以核心路由器或 Wi-Fi 网络接入点的固件升级这一高风险场景为例。此类变更虽然对网络安全和稳定性至关重要，但如果时机把握不当、执行不到位，也可能带来严重的运营风险，进而引发大规模网络中断。


那么此时机器学习模型就可以将固件变更(如安全升级、性能优化或稳定性修复)与历史同类变更的表现进行关联分析，并结合部署环境，与以下可量化的运营指标建立关联：

- **网络相关服务请求量：**部署后新增的事件工单或请求数量
- **停机时长：**受影响网段（如路由器、调制解调器等）出现的计划外中断或延迟问题
- **变更成功率：**此类固件变更中未引发事故的比例
- **升级事件数：**变更后被上报至更高层级处理的问题数量
- **平均解决时间（MTTR）：**因变更引发问题的平均解决耗时

模型部署完成后，便能为每一个变更场景生成精确的“影响评分”，量化其引发中断或性能下降的可能性。该评分成为衡量固件升级潜在运营风险的重要指标。

这一影响评分将成为“假设情景模拟”的基石。借助这些情景分析，IT 领导者能够对固件升级的部署顺序进行优先排序、延后或重新规划。

如图所示：核心路由器某月份安全升级的部署量，会如何影响不同月份所计算出的影响评分。



这项分析清晰地揭示了升级类型的变化——或升级类型、部署时间、部署频率与目标网段的特定组合如何直接影响运营稳定性，进而决定这些部署的整体成功率。

这一可视化分析清楚地表明：在核心路由器上部署安全固件升级，在 6 月和 12 月这类月份很可能引发严重的运营中断或影响。与之形成鲜明对比的是，4 月和 7 月等月份中，同一固件类型在同一网络设备上的影响评分则明显偏低——这有力地说明，这些时段可能更适合进行大规模、积极的升级部署。

有了这些洞察，IT 团队便可以战略性地重构固件升级策略，采用混合方案：

- 对高影响固件类型采取更分散、分阶段的部署方式
- 在预测影响较低的月份提高部署频率
- 对历史故障关联度较高的设备类型，延后升级或先在沙箱环境中进行验证
- 在高影响月份，仅安排频率更低、管控更严格的极关键性升级。

由此可见，将变更影响模型融入基于机器学习的“假设情景”分析后，IT 团队便获得了在实施前测试和评估潜在变更的关键能力，大幅降低变更部署相关的事件风险，并确保在不损害运营稳定性和效率的前提下，及时推进各项变更。

借助机器学习实现资产健康的主动维护

在现代 IT 运维这个错综复杂的世界里，正常运行时间就是“硬通货”，等到设备出故障才去修已经行不通了。无论是服务器宕机还是关键网络设备失效，意外停机所带来的代价都可能是天文数字，直接冲击营收、声誉和客户信任。

遗憾的是，许多 IT 团队至今仍依赖静态的健康评分阈值或人工巡检来判断资产状态。维护工作长期以来都是被动式或按固定周期进行的，由此带来的后果不容小觑：

- **意外停机：**突发故障导致业务中断，造成高昂损失和生产力下降
- **资源配置低效：**维护团队往往被动出动，不是仓促抢修，就是进行不必要的维护
- **资产提前报废：**资产可能仅仅因为到了预设周期就被更换，而非基于其真实状态，造成资本浪费
- **错失优化机会：**缺乏对资产健康状况的洞察，就无法优化性能或延长使用寿命。


真正的目标，是从这种“坏了再修”的思维彻底转变为在故障影响运营之前就主动预判、提前处理。而这正是基于机器学习的资产风险与性能评分所能实现的。

每一项 IT 资产——无论是终端设备、服务器、网络交换机、VPN 网关，还是任何关键基础设施——都会持续留下数据轨迹。这些“数字痕迹”包括 CPU 周期、内存峰值、磁盘 I/O、网络延迟、平均故障间隔时间(MTBF)日志、温度读数以及各类错误代码。而这些数据点当中，都蕴藏着可被用来提前预判故障的预测信号。

机器学习模型擅长分析这些复杂的使用模式、环境因素和历史数据，从而预测故障的发生。

这使得真正意义上的主动维护成为可能——确保干预措施在恰当的时机精准介入，从而延长资产使用寿命、最大限度减少高昂的停机损失。

借助无代码机器学习构建工具，IT 运维团队现在可以创建定制化的机器学习模型来预测资产故障。这些模型可以基于历史使用数据和性能指标进行训练，识别出通常预示故障发生的模式，例如资产使用年限、CPU 与磁盘活动的骤增、MTTR、MTBF、温度日志，以及遵循可预测生命周期曲线的历史故障事件。



这项全面分析为 IT 团队提供了清晰、前瞻性的整体资产健康视图。该模型能够智能整合数十项指标，为每一项资产生成综合故障风险评分，使 IT 团队能够在灾难性事件发生前主动安排维护。

例如，可视化图表清楚地显示，资产编号 DB-514-AMS 的故障概率较高，其未来 15 天的预测故障风险评分达到 80%。这一风险骤升，是由错误率近期激增、告警数量增多以及温度持续偏高共同导致的。与之形成鲜明对比的是，资产编号 SRV-002-LAX 尽管运行年限相近，但其未来 15 天的故障概率始终保持在低位(低于 5%)。

有了这些洞察，IT 团队便可以从战略层面重构维护工作。与其坐等资产故障或提前更换，不如有计划地安排资产的替换时机。

通过部署此类定制化的无代码机器学习预测性维护模型，IT 团队在资产管理方式上实现了根本性转变：

- **减少计划外停机：**提前预判故障意味着干预可以被有计划地安排，避免代价高昂的中断
- **优化维护计划：**只在真正需要时才进行维护，延长资产寿命，减少不必要的人力和成本投入。
- **延长资产使用寿命：**基于真实状态的主动维护，让每项资产的投资回报最大化
- **增强运营韧性：**系统保持稳定、性能最优，从而提升服务交付水平和用户满意度

预测性维护——这一曾被视为复杂任务的工作——如今已成为一种易于使用且自动化的能力。这使 IT 和运维团队能够专注于更高层次的战略目标，将资产管理从被动应对的负担转变为主动提升效率和可靠性的驱动力。

04 借助定制化预测平衡分布式基础设施容量

随着组织规模不断扩大、数字化转型持续加速，IT 基础设施也变得日益复杂——并且不可避免地趋向分布式。

如今，应用和工作负载早已不再局限于单一地点，而是分散在数据中心、公有云、私有云以及混合环境之中。这一转变也带来了新的挑战：资源使用模式变得难以预测。

在这样快速变化的现代环境中，工作负载会实时波动，其驱动因素包括内部运营需求、客户行为变化、高影响力营销活动，乃至安全事件。这种高度的动态性固然是数字化成熟度的体现，但也带来了一些实际运营痛点：

- **基础设施利用不足：**存储、算力等昂贵资源常常处于闲置状态，一旦需求发生意外变化，便会造成资金浪费和效率下降。
- **部分资源过度使用：**与之相反，某些关键资源和系统则被压榨到极限，一旦需求骤增超出静态分配的承受范围，便会导致系统变慢、性能下降，甚至彻底故障。

造成这些低效问题的一大主因，是目前依然普遍采用的传统容量分配方式——它通常依赖行业经验、静态规则、笼统假设，或单纯的历史趋势，常常导致效率长期低下、成本大量流失。

亟需预测性容量平衡

要实现有效的容量分配和平衡，IT 团队必须具备清晰的预见性，并主动掌握其基础设施各部分将在何时、何地以及以何种方式面临压力或资源浪费。因此，迫切需要一种解决方案或系统，能够在基础设施失衡造成损害之前预先察觉到这种失衡。

正是在这种情况下，像 Analytics Plus 的 AutoML 这样的无代码机器学习构建工具，为组织提供了一条革命性的、无需编码的途径，使其能够在几秒钟内创建用于容量平衡和分析的复杂定制模型。

AutoML 通过分析海量的历史数据（包括服务器性能、工作负载分布、资源请求量以及实际资源使用情况）来运作。随后，它会自动创建量身定制的机器学习模型，这些模型专门设计用于：

- **动态波动的工作负载需求：**可能源于意外的流量激增、难以预测的应用行为，或营销活动、重大软件更新等战略性业务事件
- **突发且不可预测的使用模式：**这些情况毫无征兆地出现，使传统、僵化的预测

模型根本无法准确预判负载。因此，面对由动态且往往不可预见的使用模式变化所驱动的现代企业需求，标准工具和通用报表已难以满足其独特而复杂的容量平衡需求。

针对动态基础设施的定制化模型

组织需要采用能够真正理解自身独特状况、不断演变的使用模式、动态需求、基础设施复杂性、市场趋势和特定业务目标的定制化机器学习分析模型，从而实现：

- 主动识别可能对资源使用模式造成重大影响的隐藏趋势、事件或潜在因素
- 预测资源何时将出现高负载，并自动触发负载均衡、资源重新分配或动态扩缩容等纠正措施
- 优化资源使用，确保关键基础设施不会不堪重负，同时避免闲置资源浪费宝贵资本

然而，聘请专业数据分析师来构建定制化分析模型，所需的额外成本，加上耗费的大量时间和资源，往往令 IT 领导者望而却步。而依赖现有工具内置的通用能力，又可能因结果不准确，导致因未能及时应对的失衡问题而扰乱整体运营。

借助 Analytics Plus 的 AutoML，IT 团队可将复杂的容量平衡建模流程转化为可重复、可快速迭代的分析能力，无需依赖专业编码即可根据业务变化调整模型。

这使定制化容量平衡分析能够在不增加编码负担的前提下快速落地。

该无代码机器学习模型通过分析海量历史数据——包括服务器性能、工作负载分布、资源请求量以及实际资源使用情况——自动创建专为以下目标设计的定制化模型：

- 在潜在的基础设施失衡发生之前就予以发现
- 预测使用模式的动态变化及突发事件可能如何导致用户行为改变，从而引发基础设施的过度使用或利用不足

试想一家企业级 SaaS 公司，常常因为功能上线或营销活动带来的用户活跃度意外激增，而经历工作负载分布不均的情况——而依赖静态规则的传统模型根本无法应对这种情况。

借助无代码机器学习构建工具，NOC(网络运维中心)团队可以创建定制化模型，分析历史遥测数据，并检测流量、安全事件、用户行为和资源健康状况等方面的模式。



这项分析展示了定制化容量平衡模型如何利用长达 12 个月的历史遥测数据，预测关键基础设施资源或服务的动态负载风险评分。

该预测综合考量了丰富的影响因素：峰值使用场景、安全漏洞事件、其他突发状况，以及导致基础设施健康数据(CPU、内存、磁盘利用率、延迟)出现不可预测波峰或波谷的历史事件。

该分析清楚地表明，机器学习模型的预测能够精准追踪不断变化的负载风险，即便面对意料之外的激增也不例外。有了这种预见能力，团队便可以制定自动化策略，将流量动态重新路由至利用率较低的节点，或对资源进行弹性扩缩容。

基于定制化机器学习预测所实施的自动化流量重定向策略，能够带来显著收益：

- **减少基础设施事件：**主动式的容量平衡能够预防瓶颈和性能下降
- **优化云成本支出：**资源利用更加高效，避免不必要的扩容
- **提升基础设施相关请求的 SLA 达标率，**得益于提前采取的预防措施

通过部署这类定制化的无代码机器学习容量平衡模型，IT 团队在基础设施管理方式上实现了根本性的转变：

- **主动式资源分配：**提前预判负载高峰，防患于未然，避免服务中断
- **成本节约：**智能利用闲置资源，优化云支出，大幅降低浪费
- **无缝弹性扩展：**系统无需人工干预即可自动触发必要的扩缩容，确保应用始终获得充分支撑

长期以来，容量平衡一直是一项被动式的工作。而如今，借助触手可及的预测模型，IT 团队终于可以将其转变为主动、智能的流程。这使 NOC 团队得以将精力集中在更高层次的战略目标上，从而为未来打造更具韧性、更具成本效益、更加敏捷的 IT 环境。

结语


从被动式问题处理转向主动式战略 IT 管理，已不仅仅是一种愿景，更是当今复杂数字世界中的必然选择。机器学习驱动的分析，提供了将原始数据转化为可执行洞察所需的智能能力，把潜在危机转变为可控的结果和更明智的决策。通过阅读本电子书所探讨的这些先进分析能力，IT 团队将得以突破传统方法的局限，确保运营稳定性、优化资源利用效率，并进一步强化安全防线。

关于

ManageEngine Analytics Plus 是一款 IT 分析与决策智能解决方案，旨在为企业提供 IT 运营的统一视图，梳理各系统间的相互依赖关系，并从中提炼有价值的洞察。它通过整合本地与云端基础设施的关键指标(KPI)，打破数据孤岛。Analytics Plus 可衡量网络运营效率、追踪业务应用的响应速度与可用性、评估技术人员绩效、跟踪流程进展，并标记安全异常。

这些整合后的洞察，旨在帮助企业做出数据驱动的决策，从而提升运营效率、推动业务成功。

如需了解更多关于 Analytics Plus 的信息，请访问
www.manageengine.cn/analytics-plus/



参考

[1] SAP LeanIX AI Survey Results 2024: <https://www.leanix.net/en/download/sap-leanix-ai-survey-results-2024>



© ManageEngine, a division of Zoho Corporation