

线上故障应急手册

版本: v1.0
适用对象: 运维、SRE、应用 Owner、值班工程师
核心原则: 先恢复，后定位；先止血，后根治

一、故障分级标准

级别	定义	响应时间	升级机制
P0	全站不可用 / 资损 / 数据丢失	立即响应	5min 内升级至总监级
P1	核心功能不可用 / 大面积降级	5min 内响应	15min 内升级至 Leader
P2	部分功能异常 / 性能严重下降	15min 内响应	30min 内同步值班长
P3	非核心功能异常 / 体验问题	1h 内响应	走工单流程

二、应急响应 5 步法（黄金 30 分钟）

Step 1：发现与确认（0~3 分钟）

- ☐ 接收告警（Zabbix/Prometheus/夜莺/自研监控）
- ☐ 多渠道交叉验证（监控大盘 + 用户反馈 + 日志抽样）
- ☐ 避免误判：先看大盘全站指标，再下结论
- ☐ 在应急群内同步："【疑似 P?】现象 + 时间 + 影响面"

Step 2：定级与拉群（3~5 分钟）

- ☐ 按上述标准定级
- ☐ P0/P1 立即拉应急群（IM 群 + 电话会议）
- ☐ 角色分工：
 - Incident Commander（指挥官）：1 人决策，不参与具体操作
 - Ops 处置：执行回滚/切流/扩容
 - 研发排查：定位代码/中间件问题
 - 沟通官：对外 PR、对内同步进展

Step 3：止血 / 恢复（5~15 分钟）

第一原则：恢复服务优先，不要边查边修！
常用止血手段优先级排序：

优先级	手段	适用场景	操作示例
P0-1	流量切换/降级	单机房/单集群故障	DNS 切流、LVS/Nginx 下线故障节点
P0-2	服务回滚	刚发布导致	<code>kubectl rollout undo</code> / 蓝绿切换
P0-3	熔断/限流	依赖方超时雪崩	Sentinel/Hystrix 触发降级规则
P0-4	关闭非核心功能	资源耗尽	关闭推荐、关闭日志采集、关闭定时任务
P0-5	扩容	容量不足	临时扩容 ECS/Redis 分片/数据库连接池
P0-6	重启服务	进程僵死/内存泄漏	滚动重启、强制 kill -9 后拉起

Step 4: 根因定位 (15~30 分钟)

- ☐ 5 Why 分析：从现象倒推至少 5 层
- ☐ 查看时间线：监控告警 → 发布记录 → 流量变化 → 依赖方状态
- ☐ 工具箱：
 - APM: Skywalking/Cat/Pinpoint 看慢调用链路
 - 日志: ELK/Loki 关键字检索 (traceId)
 - JVM: jstat、jmap、arthas 在线诊断
 - DB: 慢 SQL、锁等待、连接池
 - 网络: tcpdump、mtr、iftop

Step 5: 收尾与复盘 (24h 内)

- ☐ 故障恢复后持续观察 30 分钟再撤离
- ☐ 1 个工作日内完成 RCA (Root Cause Analysis) 报告
- ☐ 3 个工作日内输出改进 Action 并跟踪闭环
- ☐ 5 个工作日内组织复盘会 (无指责文化, 聚焦流程改进)

三、典型故障场景速查表

● 场景 1: 服务 502/504 飙升

- Nginx upstream 健康检查是否正常
 - 后端进程是否存在 (ps -ef | grep java)
 - 端口是否监听 (netstat -tlnp | grep port)
 - 是否有 OOM (dmesg | grep -i oom)
 - 连接池是否打满 (DB/Redis 客户端监控)

● 场景 2：数据库慢查询

1. `show processlist` 看当前会话
2. `information_schema.innodb_trx` 看长事务
3. 慢日志定位 SQL
4. 紧急 `kill` 阻塞会话: `kill <id>`
5. 必要时切换只读副本

● 场景 3：Redis 集群故障

1. 哨兵/Cluster 状态: `redis-cli cluster info`
2. 是否触发脑裂: 检查多数派
3. 内存是否打满: `info memory`
4. 是否有 `bigkey` 阻塞: `redis-cli --bigkeys`
5. 紧急 LRU 调整: `CONFIG SET maxmemory-policy allkeys-lru`

● 场景 4：K8s 节点 NotReady

1. `kubectl describe node <node>`
2. kubelet 状态: `systemctl status kubelet`
3. 磁盘: `df -h` (默认会因 `disk pressure` 驱逐)
4. 网络: `calico/flannel` 组件状态
5. 临时解封: `kubectl uncordon <node>`

● 场景 5：磁盘写满

1. `du -sh /*` 定位大目录
2. 清理日志: `journalctl --vacuum-time=3d`
3. 清理 Docker: `docker system prune -a`
4. 扩容云盘 (生产慎用, 需先备份)

四、沟通模板

4.1 故障公告 (内部)

【P1 故障通报】

时间: 2024-XX-XX HH:MM

现象: xxx 接口成功率下降至 xx%

影响: 约 xx% 用户

当前措施: 已切流至备用集群

负责人: @张三 @李四

下一同步: 15 分钟后

4.2 用户公告（外部）

【服务异常通知】

亲爱的用户，我们当前监测到 xxx 功能出现异常，
技术团队正在紧急处理中，预计 XX 分钟内恢复。
给您带来不便，敬请谅解。

五、不可触碰的红线

- 1.  生产环境禁止 rm -rf / （哪怕加通配符）
- 2.  禁止在排查时直接修改线上数据（必须先备份）
- 3.  禁止单人操作核心数据库 DDL（需双人复核）
- 4.  禁止跳过灰度直接全量发布
- 5.  禁止故障期间发表定性结论（未定位完成前只说现象）
- 6.  禁止隐瞒故障不上报（哪怕只影响了 1 个用户）

六、值班与交接规范

- 值班表提前 2 周排定，不接受口头换班
- 交接必须书面化：遗留告警、进行中变更、风险点
- P0/P1 故障必须通宵直至恢复稳定
- 重大变更（发布、迁移、割接）禁止安排在周五/节假日前一天

七、附录：常用应急命令速查

查看系统整体状态

top -c | head -20
vmstat 1 5
iostat -x 1 5
ss -s

查看网络连接

ss -tan state established | wc -l # ESTABLISH 连接数
netstat -an | grep ESTABLISHED | awk '{print \$5}' | awk -F: '{print \$1}' | sort | uniq -c

进程级定位

ps aux --sort=-%cpu | head -10
ls /proc/<pid>/fd | wc -l # 进程打开 fd 数

日志实时跟踪

tail -F /var/log/messages
journalctl -u <service> -f --since "10 min ago"

K8s 应急

```
kubectl rollout undo deployment/<name>
kubectl scale deployment/<name> --replicas=0 # 紧急下线
kubectl get pods -A | grep -v Running

# 抓包
tcpdump -i eth0 -nn -s 0 -w /tmp/cap.pcap host <ip> and port <port>
```

手册维护：本手册应由 SRE 团队每季度 review 一次，结合实际故障案例持续迭代。

反馈渠道：[内部 Wiki 链接] / 邮件至 sre@company.com