


Anomaly Detection

für unternehmenskritische Applikationen in heterogenen IT-Umgebungen

Susanne Greiner



Einführung



Abhängig von

- Pathologie
- Sport
- Atmung
- Pharmaka
- Temperatur
- Dehydration
- Druck
- Etc.


Monitoring & Alarme

Personenspezifische Daten




Erwartung

- Zeitreihe
- Alarm Schwellwerte



Bevölkerungsdaten





Abhängig von

- Batch requests
- Transactions
- Memory
- SAN
- Network
- Side Processes
- Etc.

Monitoring & Alarme


Spezifische Maschinen
Daten




Erwartung

- Zeitreihe
- Alarm Schwellwerte

Erfahrung,
Daten ähnlicher Machines/ Settings






- Jede Zeitreihe wird **einzeln** analysiert
- Schwellwerte werden via **Baselining** berechnet
- Alarme verschiedener Zeitreihen werden zu einem **globalen Alarm** kombiniert
- Abhängigkeiten zwischen den Zeitreihen werden **ignoriert**
- Form der Zeitreihe wird **ignoriert**

Motivation

- Unterschiedliche Datenquellen
- Unterschiedliche Aufzeichnungsgenauigkeiten
- Evolution der Netzwerkkomplexität: Common Practice **war** genug




- Alle Zeitreihen werden **zusammen** analysiert
- Schwellwerte werden via **Baselining und Anomaly Detection** errechnet
- **Risk Berechnung** zusätzlich zu **globalen und spezifischen Alarmen**
- **Abhängigkeiten** zwischen Zeitreihen werden verwendet um die Alarmqualität und Risks zu verbessern
- Form der Zeitreihe wird berücksichtigt


Motivation

- Gemeinsame Datenquelle
- Grafana & InfluxDB
- Heute braucht es mehr als Common Practice
- **Proactivity**

Metriken




Baselining



**MACHINE LEARNING
ADVANCED STATISTICS**

Risk




Visualisierung



Alerts


Details

Eine gemeinsame Datenquelle




- Kommunikation mit nur einer Datenquelle
- Verstehen nur eines Outputtyps
- Vergleich homogener Daten

VORHER




NACHHER




- Bereiche statt (zu) vieler Punkte
- Geglättetes Signal


VORHER



- Vergleich von Zeitintervallen schwierig
- Quantifizierung von Effekten kaum möglich




NACHHER



- Historische Daten griffbereit
- Differenzenvisualisierung
=> Einfache Effektquantifizierung

Risk als Ergänzung der Standard Alerts: Berechnung


DATASET



Standard: jede Zeitreihe wird einzeln analysiert und mit ihrem eigenen Standardverhalten verglichen

FEATURE SPACE

jeder Zeitpunkt: Zustand, der eine *Standard* | *nicht Standard* Situation charakterisiert





Multivariate analysis: jeder Zeitpunkt wird analysiert, dabei werden neben den einzelnen Werten jeder Metrik ihre Gesamtkonstellation betrachtet

OUTPUT

RISK:


Anders als der 'Standard'






Globales Risk:

Zeitpunkte mit Werten, die bezogen auf die Metriken, die herangenommen wurden, merklich anders sind wenn man sie mit historischen Daten vergleicht



Spezifisches Risk:



Zeitpunkte deren Wertekonstellation nicht dem Standard entspricht verglichen mit historischen Daten des selben Tages



Duration Risk:

Zeitpunkte deren Wertekonstellation nicht dem Standard entspricht verglichen mit historischen Daten des selben Tages, die zusätzlich in der Nähe weiterer nicht Standard Datenpunkte liegen

Agile Implementation




Lösung wird dank agiler Implementierung sehr kundenspezifisch

Use Cases

„Ist Zustand“ und Dynamik meines Systems?

VORHER




Daten können schneller und einfacher interpretiert werden
Auffälligkeiten können einfach kommuniziert und geteilt werden


NACHHER



Troubleshooting



Beispiel I: Large Scale Fehleranalyse




Ein ganzer Monat Daten, wo macht Fehleranalyse am meisten Sinn ?


Beispiel I:



Beispiel I:



Beispiel I:



Beispiel I:



Root Cause:
In der für den SQL Server reservierten VM laufen zeitweise auch Transaktionen anderer Prozesse, die eigentlich notwendige Operationen ausbremsen

Die Kombination aus


- *Langzeittrend*
- *Historischen Daten*
- *Risks*
- *Relog & EsxTop Metriken*

machte die Detektion und Lösung des Problems möglich

Beispiel II: Detektion und Optimierung sich wiederholender Events



Beispiel II:




Zoom:

*Es scheint jeden Tag zur gleichen Zeit
Nachts ein Event stattzufinden, dass sich
von den "Standard" Daten merklich
unterscheidet.*

Rücksprache mit Systemadministrator


-> optimierbarer Cronjob

Beispiel II:



Nur wenige VMs
haben ein hohes
Risk

VMs, die mehrfach
ein hohes Risk
haben sollten zuerst
analysiert werden




Zusammenfassung


Homogene Ansicht unterschiedlichster Metriken

DATENQUELLE
relog

DATENQUELLE
esxtop




**Multivariate RISKS
berechnet aus mehreren Metriken
(alle oder eine Auswahl)**




- Schnelleres Troubleshooting
- Mehr Zeit für Root Cause Detection



**Historische Daten immer griffbereit
Unterschiede zu den historische Daten
bereits berechnet**



Glättung, Bereiche & optimierte Genauigkeit




Lade immer nur so viele Daten, wie für die Visualisierung benötigt
Multimeasure Zoom




Optimaler Kompromiss:
Genauigkeit vs. Speed




Einfache Trenderkennung mit
geglätteten Kurven



Metrics



**MODELL
STANDARD
VERHALTEN**



**RISK
SCORE**


- Je weiter die Wertekonstellation an einem Zeitpunkt vom Standard entfernt ist, um so höher das Risk
RISK: anders und selten

WIE WEIT SIND WIR VON UNSERER ERWARTUNG ENTFERNT?

- Historische Daten der gleichen Metrik
- Historische Daten ähnlicher Metriken
- Historische Daten ähnlicher Maschinen

WAS ERWARTEN WIR?

IOs



- Welche Maschine(n) ist am wahrscheinlichsten für hohes Risiko verantwortlich
- Proaktive Analysis um Überlastung vorzubeugen



- Historische Daten der gleichen Metrik
- Historische Daten ähnlicher Metriken
- Historische Daten ähnlicher Maschinen
- Historische Daten von Nachbarn

Proaktive Suche von potentiell in der Zukunft gefährlich werdenden Settings

Schnelleres Troubleshooting




- Maschinen mit hohem Risk sollten zuerst untersucht werden, möglicherweise erübrigt sich die Kontrolle der anderen

Fazit

- Risk ist eine nützliche Erweiterung existierender Standard Verfahren
- Weniger, relevantere Alarme
- Situationen die nicht bei Standard Methoden gefunden werden sind detektierbar
- Beziehungen von Metriken untereinander und AD spielen eine Schlüsselrolle für erfolgreiches Next Level Performance Monitoring
- Einsatz menschlicher Experten ist optimiert
 - Kann sich aufs WAS konzentrieren (und dessen Lösung)
 - Weniger Zeitaufwand, um nach dem WO zu suchen=> Schnelleres Troubleshooting
 - Proaktives Performance Monitoring (Problem Prävention)

Abhängigkeiten



Monitoring & Alarme

Spezifische Daten




Erwartung

- Zeitreihe
- Alarm Schwellwerte




Erfahrung,
ähnliche Daten



**Vielen Dank für Ihre
Aufmerksamkeit**


Supplementary

Beispiel III: Minor Event



Proaktive Analyse kleinerer Events mit Risk...

Beispiel III: Minor Event




Beispiel III: Minor Event




Beispiel III: Minor Event


Vormonat



Monat der Analyse



*Ein Cronjob war so konfiguriert, dass immer am letzten Freitag des Monats (Mittag 12:00) ein Speichervorgang stattgefunden hat durch zunehmende Daten hätten dadurch negative Auswirkungen entstehen können.
Lösung: Ein anderes Zeitmanagement und Optimierung des Prozesses*






multidimensional data
multivariate methods





ignoring multidimensionality
=> more false alarms misses

- ✕ is close to the max and mean of metric 1
- ✕ is close to the max and mean of metric 2
- ✕ is not a very probable request in a multidimensional view

➔ a 1D view is not the perfect option for certain types of networks or applications


Anomaly Detection






Automatic detection
of relevant changes

Culprit Detection: Which VM should I blame



Culprit Detection: Which VM should I blame



Threshold on risks not on IO counters



Culprit Detection: Which VM should I blame

