

# イベントの確率分布推定による サービスレベル違反の予兆検出精度向上

外川遼介 登内敏夫

NEC サービスプラットフォーム研究所

## 1. はじめに

高信頼なクラウドコンピューティングを実現するために、可用性や性能などのサービスレベルを保証することが重要である。サービスレベルを維持するために、サービスレベル違反の予兆を発見し、事前に対策を講じることが望まれる。

本論文では、サービスレベル違反の発生確率を推測する方法を提案する。また、実機を用いて、提案方式を評価した結果を報告する。

## 2. 従来手法の課題

予兆検出の従来手法には、単純ベイズ分類器による手法[1]がある。これは、サービスレベル違反に関わるシステムエラーなどのイベントを適切に選択した上で、サービスレベルの違反結果と選択したイベントの発生回数とを学習事例とし、サービスレベル違反の発生確率を算出する。

しかし、以下の二つの課題がある。

第一に、単純ベイズ分類器による予兆検出手法は、サービスレベル違反に関わるイベントの発生回数に基づくものであるため、選択したイベントが適切でなければ、算出される違反確率の精度が低くなる。したがって、どのような計測値や事例を予兆の判断指標とするかが従来手法の課題である。

第二に、学習データにおいてサービスレベル違反やイベントの発生回数が 0 または数例など少数の場合には、違反確率の推測精度が低くなるという課題である。これは、発生回数が少ない場合、本来のイベントや違反の発生回数の正確な分布と学習データとの誤差が大きくなる傾向があるために生じる。

## 3. 提案手法

単純ベイズ分類器をもとに、適切なイベントの選択手法と、確率分布推定による学習事例が少ない場合への対応手法を提案する。

第一に、既存の単純ベイズ分類器では、エラーメッセージなど外部で観測されたイベントを利用して推論を実施している。すなわち、イベントが、

サービスレベルの値の変動として反映されると仮定している。しかし、イベントの中には、サービスレベルの値の変動と相関の低いものも含まれており、それが、違反確率の推定精度を下げる一因となっている。そこで、外部のイベントの反映である、サービスレベルの値の特徴的な変動をイベントとして選択する。

第二に、サービスレベルの値に対して確率分布を仮定して、学習データより確率密度を計算し、単純ベイズ分類器を用いる。確率密度を計算することで、少数であってもサービスレベル値の頻度分布を補間することが可能となる。

次に、具体的な算出過程について説明する。すなわち、ある時刻  $t$  にイベント  $E_i$  ( $i=1, \dots, n$ ) が発生した場合について、 $\delta t$  秒後までにスループット等のサービスレベルが目標値  $v_0$  より悪化する確率を求める方法を説明する。

- i. イベント  $E_i$  発生後  $\delta t$  秒間のサービスレベルの値の中で、サービスレベルが劣化した値を  $p_{\text{worst}}$  とする。
- ii. 学習用データより、イベント  $E_i$  発生時の  $p_{\text{worst}}$  の確率分布  $M_i$  を推定する。ただし、 $p_{\text{worst}}$  は正規分布すると仮定する。
- iii. 推定した確率分布  $M_i$  を用いて、イベント  $E_i$  発生時のサービスレベル違反確率を推定する。すなわち、イベント  $E_i$  発生時にサービスレベル値が事前に決めた閾値  $v_0$  より劣化する確率、すなわちサービスレベル違反確率  $P(\times | E_i)$  を求める。ただし、“ $\times$ ” はサービスレベル違反を表す。
- iv. 監視対象のログにおいて、同時に単数ないし複数のイベント  $E_i$  ( $i=1, \dots, n$ ) が発生した場合、1~3 までに算出した違反確率  $P(\times | E_i)$  を用い、ベイズの定理よりサービスレベル違反確率  $P(\times | E_1, \dots, E_n)$  を求める。

## 4. 実験結果

WEB 三層モデルを想定し実機評価を実施した。評価システムの構成は、WEB サーバ 1 台、AP サーバ 4 台、DB サーバ 1 台である。また CPU 使用率やスループットなどのパラメータを計測するためにベンチマークソフトである RUBiS を使用した。さらに、実験条件として、性能負荷パターンを変化させてパラメータを計測した。提案手法の学習用、検証用データとして、それぞれ 10 分間、60 分間計測を行ったものを使用した。本評価では、スルー

Improved method for a prediction of SLA violation with estimation of the probability distribution

Ryosuke Togawa, Toshio Tonouchi  
Service Platform Laboratories, NEC

プットをサービスレベル値とした。

提案手法に基づきサービスレベル違反確率を算出し、イベントごとの違反確率を比較した。尚、イベントとして、サービスレベル値の変動に基づくイベント A~C を選択した。A はサービスレベル値が増加傾向に変化したイベント、B は極端な変動が生じたイベント、C は時間平均値が増加したイベントである。さらにサービスレベル値が  $0.8v_0$  以上  $1.2v_0$  以下のイベント  $E_v$  を用いた。

上記 4 種類のイベントを組み合わせた 7 種類のイベントについて、学習データより計算した違反確率と検証用データにおける違反確率からイベントごとの誤差率を計算した結果を図 1 に示す。




図 1: イベントごとの違反確率の誤差率

相互に独立したイベントである A~C は比較的大きな誤差率を示しているが、これらとイベント  $E_v$  が同時に発生している場合には、誤差率が大きく減少していることが指摘できる。したがって、サービスレベル値自体の変動を最もよく反映していると考えられるイベント  $E_v$  と外的なイベントの効果とみなしたイベント A~C の重ね合わせにより高い精度で違反確率が算出できた。

### 5. 考察

本実験の結果より、次の二点が考察できる。

第一に、イベントの組み合わせに関する点である。結果より、イベント  $E_v$  を併せて考えることにより計算精度を向上させることができた。しかし、一様に向上するのではなくイベントごとに違いが存在した。特にイベント  $A \cap E_v$  では他の 2 つに比べ誤差率の減少が小さい。それには各イベントと違反事例との関わりが影響している。表 1 として、学習事例における各イベント、違反事例の発生回数を示す。

これより、全体の違反回数に対して  $E_v$  発生時の違反回数が占める割合が高いために、重ね合わせにより違反確率の精度が向上したことが考えられる。イベント A に対して精度の向上が低かったのはイベント A とイベント  $E_v$  の違反事例の相関度が高く、互いに独立という条件から大きくずれてい

たためと考えられる。今後、どの程度の相関が許容されるのか検討を加える必要がある。

表 1: 学習データにおける各イベント、違反回数

イベント	A	B	C	$E_v$	全体
イベント発生回数	218	5	51	148	672
違反回数	48	2	25	40	49

第二に、検証データにおけるイベントと違反の発生のばらつきに関する点である。図 1 では、検証データ全体を対象に、違反確率の算出を行った。しかし、検証データでは、イベントや違反の発生回数の時間的分布にばらつきがあると考えられる。そこで全体を 3 つの区間( $t_1, t_2, t_3$ )に均等に分割し、それぞれ区間での違反確率の誤差率を比較した。その結果を表 2 に示す。

$t_1$  ではイベントが発生しないため、誤差率を 0 とみなしている。また、 $t_2, t_3$  では誤差率にばらつきがみられる。これは各区間において、イベントの発生回数に違いがあるためであり、その分布と学習データがよく合致していれば精度が向上すると推測される。

表 2: 区間別の違反確率の誤差率

	$t_1$	$t_2$	$t_3$
イベント A	0	0.46284	0.778129
イベント B	0	0.46252	0.46252
イベント C	0	0.476816	0.463147
イベント $E_v$	0	0.697064	0.689938
イベント $A \cap E_v$	0	0.389266	0.380916
イベント $B \cap E_v$	0	0.015104	0.26888
イベント $C \cap E_v$	0	0.087893	0.060617

### 6. まとめ

本論文では、単純ベイズ推定に基づく手法を用いてサービスレベル違反確率を算出するためのイベント選択方法について論じた。実機評価の結果、サービスレベルの変化をイベントとして用いるとともに、それらのイベントを組み合わせて推定することで、予測精度が大幅に向上することを示した。ただし、相関性の高いイベントの組み合わせでは効果が少ないことが重要であると判明した。今後、最適なイベント選択アルゴリズムを検討していく。

### 参考文献

[1] Pedro Pazzani, On the Optimality of the Simple Bayesian Classifier under Zero-One Loss, 1997