

要約：

サービス稼働率向上のための計算資源故障傾向予測モデルの提案

Predicting Node Failure in Cloud Service Systems

*Qingwei Lin, Ken Hsieh, Yingnong Dang, Hongyu Zhang,
Kaixin Sui, Yong Xu, Jian-Guang Lou, Chenggang Li,
Youjiang Wu, Randolph Yao, Murali Chintalapati, Dongmei Zhang*

(ESEC/FSE 2018) European Software Engineering Conference and
Symposium on the Foundations of Software Engineering: Pages 480 - 490

発表者 木村 祐太



背景

クラウドコンピューティング

- Infrastructure as a Service (IaaS)

ハードウェアリソース (CPU/メモリ/ストレージ)

- Platform as a Service (PaaS)

開発プラットフォーム環境 (サーバーの設置/OSのインストール/ネットワークの設定)

- Software as a Service (SaaS)

ユーザがインターネットを経由してサービスを利用




引用 : <https://www.computenext.com/wp-content/uploads/2013/08/iaas-saas-paas.png>

クラウドサービスの普及

- 多くのアプリケーションやサービスは大規模なクラウドプラットフォームに展開
(Microsoft Azure, Google Cloudなど)
→ たくさんのユーザが利用できるようになったため、
高い稼働率を維持する必要がある
- Amazon EBS^[1]では, ”five nines”が目標
→ 99.999% (5つの9) での稼働率
1つの仮想マシンごとに, 月に26秒だけなら止まってOK

クラウドサービスの問題

- 実際には、満足できるレベルの稼働率に**満たない**
→ **コンピュータノード**の故障がサービスに深刻な
影響を与える



目的

- コンピュータノードの故障が稼働率低下の大きな原因
- Microsoftの調査では1日に全クラウドサーバの約0.1%が故障に見舞われている
→ 0.1%がかなりの悪影響を及ぼす
- コンピュータノードの故障傾向を予測するモデルMINGを提案 → サービス稼働率の向上↑

サーバの割り当て
を変更しましょう




故障の兆候が
見られます！



トラブルが
起きそう
(故障兆候)

実験



データセット

- Microsoftのクラウドサービスシステム（Azure）
- 故障ノード：健全ノード = 1：20になるようにランダムサンプリング

データセットの対象期間

	Training Period	Test Period
Dataset 1	04/01/2017 - 04/30/2017	05/01/2017 - 05/07/2017
Dataset 2	05/01/2017 - 05/31/2017	06/01/2017 - 06/07/2017
Dataset 3	06/01/2017 - 06/30/2017	07/01/2017 - 07/07/2017

Temporal と Spatial

- Temporalデータ

- I/Oスループット,
資源使用, 反応速度など

- Spatialデータ

- ノード依存関係,
ノード配置など

データの特徴例

Feature	Type	Description
UpdateDomain	Spatial	The domain where nodes share same update setting.
MemoryUsage	Temporal	Memory consumption.
DiskSectorError	Temporal	Sector errors in a disk drive.
ServiceError	Temporal	Error counts from a deployed service.
RackLocation	Spatial	The location of the rack the node belongs to.
LoadBalanceGroup	Spatial	The group where nodes' load are balanced.
IOResponse	Temporal	I/O Response time.
OSBuildGroup	Spatial	The group where nodes have the same OS build.


アプローチ

1. TemporalデータをLSTM(Long Short-Term Memory)を用いて深層学習
2. Spatialデータをランダムフォレストアルゴリズムで学習
3. 1, 2のモデルで得た学習結果を結合し, 新しく抽出したベクトルを用いてランキングモデル^[4]^[24]で学習
4. 誤分類が最小となる閾値を用い, 故障が起きる可能性の高い上位ノードを予測・評価

LSTM^[15,19,32]

(リカレントニューラルネットワーク[RNN])

- 前の情報 (Long-Term Memory) と新しい情報 (Short-Term Memory) を合わせて判断 (ループ構造を持つ)
- RNNの長期依存性の問題を解消したアルゴリズム
 - 新しい情報と関連する情報がかなり昔に記憶したものと学習が困難



アプローチ

1. **Temporalデータ**をLSTM(Long Short-Term Memory)を用いて深層学習
2. **Spatialデータ**をランダムフォレストアルゴリズムで学習
3. 1, 2のモデルで得た学習結果を結合し, 新しく抽出したベクトルを用いてランキングモデル^{[4][24]}で学習
4. 誤分類が最小となる閾値を用い, 故障が起きる可能性の高い上位ノードを予測・評価

閾値の設定

- 閾値の決定式

$$r = \arg \min_r (CostRatio * FP_r + FN_r)$$

- CostRatio :

健全ノードを欠陥として検出した数

÷ 欠陥ノードを検出できなかった数

- FP_r : 上位 r 件内で誤って欠陥ノードとして検出した割合
- FN_r : 上位 r 件内で欠陥ノードを検出できなかった割合

Research Questions

- RQ1 : 提案手法がクラウドサービスシステムのノード故障予測にどのくらい有効か？
- RQ2 : Temporal・Spatialデータは故障予測にどのくらい役立つか？
- RQ3 : 提案したランキング手法は有効か？

RQ1

(提案手法がクラウドサービスシステムのノード故障予測にどのくらい有効か?)

Table 3: The effectiveness of MING

	MING			Logistic Regression (LR)			SVM			Random Forest			LSTM		
	Precision	Recall	F1	Precision	Recall	F1	Precision	Recall	F1	Precision	Recall	F1	Precision	Recall	F1
Dataset 1	92.3%	64.2%	75.7%	69.8%	48.3%	57.1%	66.9%	53.4%	59.4%	71.6%	51.1%	59.6%	76.2%	52.3%	62.0%
Dataset 2	90.1%	67.3%	77.0%	78.6%	34.7%	48.1%	54.8%	61.1%	57.8%	80.6%	58.3%	67.7%	61.7%	60.4%	61.0%
Dataset 3	94.7%	59.1%	72.8%	59.7%	51.3%	55.2%	76.2%	44.6%	56.3%	76.3%	47.4%	58.5%	80.3%	46.3%	58.7%
Average	92.4%	63.5%	75.2%	69.4%	44.8%	53.5%	66.0%	53.0%	57.8%	76.2%	52.3%	61.9%	72.7%	53.0%	60.6%




Figure 5: The ROC curve of the comparative approaches

RQ2

(Temporal・Spatialデータは故障予測にどのくらい役立つか？)

Table 4: The effectiveness of the ensemble model

	Temporal+Spatial (MING)			Temporal only (LSTM)			Spatial only (Random Forest)		
	Precision	Recall	F1	Precision	Recall	F1	Precision	Recall	F1
Dataset 1	92.3%	64.2%	75.7%	70.6%	36.2%	47.9%	66.5%	49.3%	56.6%
Dataset 2	90.1%	67.2%	77.0%	63.8%	46.7%	53.9%	72.1%	54.7%	62.2%
Dataset 3	94.7%	59.1%	72.8%	51.4%	39.6%	44.7%	79.6%	39.1%	52.4%
<i>Average</i>	92.4%	63.5%	75.2%	61.9%	40.8%	48.8%	72.7%	47.7%	57.1%

- Temporalデータの場合
→ F1値：75.2%から48.8% ↓
- Spatialデータの場合
→ F1値：75.2%から57.1% ↓
- Temporal・Spatialは予測メトリクスとして有用

RQ3

(提案したランキング手法は有効か？)

Table 5: The effectiveness of the ranking model

	Precision	Recall	F1
MING	92.4%	63.5%	75.2%
$MING_c$ with Random Forest	85.1%	57.6%	68.7%
$MING_c$ with SVM	79.3%	56.7%	66.1%
$MING_c$ with LR	81.4%	52.6%	63.9%
$MING_r$ (<i>FastTreeRanker</i>)	91.3%	62.4%	74.1%

- まあまあいい感じ

まとめ・所感

- クラウドサービスの稼働率向上のために、ノード故障傾向予測モデルを提案
- データの特徴別に学習したランキングモデル
- サーバの数が多いため、コスト最小となるよう Precision を重視
- そこそこのいいモデルができた
- いろいろな手法の結果を用いて比較する見せ方は参考になると思う