

References

1. Vodnyj kodeks Ukrainy (2004). Kiev, Vidavnychij Dim "In Jure", 138.
2. Instrukcija pro porjadok rozrobky ta zatverdzhennja granychno-dopustymykh skydiv (GDS) rehovyn u vodni objekty iz zvorotnymy vodamy (1994). Minpryrody Ukrainy. Kyiv, 89.
3. Vremennye metodicheskie ukazaniya po ppovedeniju paschetov fonovykh koncentracij himicheskikh veshhestv v vode vodotokov (1983). Lviv: Gidrometeoizdat, 52.
4. SNA: Climate, Lakes and Rivers (1995). The National Atlas of Sweden, Almqvist and Wiksell International, Stockholm.
5. Storm, B., Refsgaard, A.; in: Abbott, M. B., Refsgaard, J. Ch. (Eds.) (1996). Distributed physically based modelling of the entire land phase of the hydrological cycle. Distributed Hydrological Modelling, Water Science and Technology Library, 22.
6. Karashev, A. V. (Ed.) (1987). Metodicheskie osnovy ocenki i reglamentirovaniya antropogennogo vlijanija na kachestvo poverhnevih vod. Lvov: Gidrometeoizdat, 285.
7. Otchet o NIR «Razrabotka normativov PDS i VSS veshhestv v vodnyj ob'ekt so stochnymi vodami dlja KP «Luckvodokanal» i predlozhenij k planu meroprijatij po dostizheniju PDS» (2011). Kharkov, UkrNIIEP, 41.
8. Obobshhennyj perechen' predel'no dopustimykh koncentracij (PDK) i orientirovochno bezopasnykh urovnej vozdejstvija (OBUV) vrednykh veshhestv dlja vody rybohozajstvennykh vodoemov (1990). Minrybhoz SSSR. Moscow, 44.
9. Proskurnin, O. A. (2012). Problemy normirovaniya vodootvedeniya stochnykh vod v vodotoki v sluchae nepolnogo razbavlenija. Ekologichna bezpeka: problemi i shljahi virishennja: materiali. Kharkiv, VD „Rajder”, 228–234.
10. Sivapalan, M., Takeuchi, K., Franks, S., Schertzer, D., O'Connell, P. E., Gupta, V. K., McDonnell, J. J., Pomeroy, J. W., Uhlenbrook, S., Zehe, E., Lakshmi, V. (2003). IAHS Science Decade on Prediction in Ungauged Basins (PUB), 2003–2012: Shaping an exciting future for the hydrological sciences. Hydrological Science Journal, 48 (6), 857–880. doi: 10.1623/hysj.48.6.857.51421

Дата надходження рукопису 20.01.2015

Адаменко Николай Игоревич, доктор технических наук, доцент, кафедра теоритической ядерной физики и высшей математики им. О. И. Ахизера, Харьковский национальный университет им. В. Н. Каразина, пл. Свободы, 4, г. Харьков, Украина, 61022

E-mail: nikolajadamenko@mail.ru

Проскурнин Олег Аскольдович, кандидат технических наук, старший научный сотрудник, Лаборатория проблем формирования, регулирования качества вод и информационного обеспечения экологического менеджмента, НДУ «Украинский научно-исследовательский институт экологических проблем», ул. Бакулина, 6, г. Харьков, Украина, 61166

E-mail: oaproskurnin@mail.ru

УДК 004.4

DOI: 10.15587/2313-8416.2015.37461

ТЕХНИКА ОБНАРУЖЕНИЯ АНОМАЛИЙ В ПРОИЗВОДИТЕЛЬНОСТИ ВЕБ-ПРИЛОЖЕНИЙ С ИСПОЛЬЗОВАНИЕМ КОЭФФИЦИЕНТА РАНГОВОЙ КОРРЕЛЯЦИИ КЕНДАЛЛА

© А. А. Сытник

В данной статье представлена техника обнаружения аномалий в производительности веб-приложений с использованием коэффициента ранговой корреляции Кендалла. Описаны теоретические этапы и проведено имитационное моделирование по определению аномалий в производительности веб-приложения. Данная техника дает возможность обнаружить аномалию производительности ВП, на основе корреляционной связи между величинами, но она не даст информации о том, где именно в исходном коде аномалия возникла и по какой причине

Ключевые слова: обнаружение аномалий, веб-приложения, коэффициента ранговой корреляции Кендалла

This article presents the anomaly detection technique in web applications performance using Kendall's rank correlation coefficient. Theoretical stages are described and simulation modeling to detect such anomalies in web applications performance is conducted. This technique makes possible to detect performance anomaly for web applications, based on correlation relationships between variables, but it doesn't give any details on where exactly the anomaly occurred in the source code and why

Keywords: anomaly detection, web applications, Kendall's rank correlation coefficient

1. Введение

Веб-приложения (ВП) подпадают под класс критически важных бизнес приложений. Они используются в разных организациях как часть бизнес процесса, поэтому сценарии спада произ-

водительности, аномалии в работе и недоступности приложения негативно влияют на качестве предоставляемых услуг. Под аномалиями подразумевают закономерности в работе модулей, которые не вписываются в нормальное поведение приложения.

Актуальною є проблема своєчасного виявлення і оповіщення про аномалії продуктивності ВП. Використання методів статистичного аналізу [1] можуть значно полегшити цю задачу. До одного з таких методів належить визначення коефіцієнта кореляції між двома величинами. Коефіцієнти кореляції використовуються для визначення сили і напрямку зв'язку між двома властивостями, вимірними за числовими шкалами (метричними або ранговими). Максимальної сили зв'язку відповідають значення кореляції $+1$ (строга пряма або прямо пропорційна зв'язок) і -1 (строга обернена або обернено пропорційна зв'язок), відсутності зв'язку відповідає кореляція, рівна нулю. В разі з ВП, якщо сила кореляційної зв'язку між двома величинами слабка, то існує ймовірність деградації продуктивності застосування і збільшення часу реакції для кінцевого користувача.

2. Аналіз літератури

Фундаментальні праці по визначенню коефіцієнта рангової кореляції (КРК) належать Пірсону [2], Спірмену [3] і Кендаллу [4]. В роботі [5] автори розробили техніку, яка дозволяє виявити аномалії продуктивності виконуючи кореляційний аналіз між параметрами застосування, зібраними з допомогою аспектно-орієнтованого програмування [6]. В другій роботі [7] автори ізолюють зміни робочого навантаження від аномалій продуктивності шляхом комбінування регресійної моделі для транзакцій і цифрової підписи застосування. Це необхідно для того, щоб визначити яка транзакція асоціюється з раптовою підвищенням навантаження на центральний процесор (ЦП). Метод, представлений в роботі [8], описує адаптовану модель моніторингу, яка дозволяє без змін в початковому коді застосування, виявити і проаналізувати шляхи проходження транзакції для налагодки продуктивності між компонентами.

3. Мета роботи

Розробити і описати техніку виявлення аномалій в продуктивності ВП з використанням коефіцієнта рангової кореляції Кендалла.

4. Задачі дослідження

Для досягнення мети були поставлені наступні задачі:

1. Проаналізувати переваги застосування КРК Кендалла для виявлення аномалій в продуктивності ВП.

2. Описати механізм застосування коефіцієнта рангової кореляції для виявлення аномалій в продуктивності ВП.

3. На основі імітаційної моделі протестувати розроблену техніку і проаналізувати отримані результати.

5. Переваги використання коефіцієнта рангової кореляції Кендалла для виявлення аномалій продуктивності веб-застосувань

Для визначення переваг застосування коефіцієнта Кендалла, виділимо слабкі сторони інших методів рангової кореляції при виявленні аномалій продуктивності ВП.

КРК Пірсона дозволяє визначити наскільки пропорційно змінюються дві змінні і характеризує існування лінійної зв'язку між двома величинами. Слабкими сторонами лінійного коефіцієнта кореляції Пірсона є: досліджувані змінні X і Y повинні бути розподілені нормально, нестійкість до викидів (один або декілька результатів спостережень різко виділяються, при порівнянні з основною масою даних). В разі з веб-застосуваннями, закон розподілення досліджуваних величин зазвичай не відомий. Також можливі різкі перепади в результатуючих значеннях.

При умові відсутності повторюваних зв'язків в рангах, по тій і другій змінній, формула Пірсона може бути спрощена і перетворена в формулу Спірмена.

Коефіцієнт рангової кореляції Спірмена визначає фактичну ступінь зв'язку між двома кількісними рядами досліджуваних ознак і дає оцінку щільності встановленої зв'язку з допомогою кількісно вираженого коефіцієнта. Недостатком рангової кореляції Спірмена виділяють неточні значення при великій кількості однакових рангів по одній або обоим порівнюваним змінним, що обмежує можливість дослідження величин, отриманих в результаті моніторингу ВП.

Альтернативою кореляції Спірмена і Пірсона для рангів представляє кореляція Кендалла. В основі кореляції, лежить ідея про те, що по напрямку зв'язку можна судити, порівнюючи між собою досліджувані: якщо у пари досліджуваних змінних по X збігається по напрямку з змінною по Y , то це свідчить про позитивну зв'язку, якщо не збігається – то про негативну зв'язку. Перевагою використання кореляції Кендалла є більш точна оцінка значень при великій кількості однакових рангів. Коефіцієнт Кендалла незалежний від закону розподілення вимірюваних величин, що є оптимальним варіантом для дослідження аномалій в ВП.

Також, коефіцієнт рангової кореляції Кендалла цілком доцільно застосовувати при наявності невеликої кількості спостережень, що позитивно впливає на продуктивність ВП в момент аналізу даних моніторингу в режимі реального часу.

6. Механізм застосування коефіцієнта кореляції Кендалла для виявлення аномалій продуктивності веб-застосувань

Коефіцієнт рангової кореляції Кендалла є мірою лінійної зв'язку між випадковими величинами. В разі з ВП ці величини можуть бути

получены посредством мониторинга компонентов приложения, а именно: времени отклика сервера на пользовательские транзакции и количество транзакций, обработанных за этот интервал времени.

Коэффициент корреляции Кендалла представлен формулой (1).

$$\tau = \frac{P(p) - P(q)}{N \frac{(N-1)}{2}} \quad (1)$$

и упрощенной формулой (2)

$$\tau = \frac{4P}{N(N-1)} - 1, \quad (2)$$

где $P(p)$ – число совпадений; $P(q)$ – число инверсий; N – объем выборки.

Механизм обнаружения аномалий в производительности ВП с использованием КРК Кендалла состоит из следующих этапов:

1. Мониторинг ВП и формирования вектора X из последовательности величин суммарного времени отклика по транзакции пользователя и вектора Y , величины которого, равны количеству пользовательских транзакций обработанных за этот период.

2. Сортировка вектора X в порядке убывания.

3. Вычисление числа совпадений P .

4. Для этого по переменной Y вычтем ранг текущего испытуемого с рангом испытуемого находящего ниже на одну строку. Положительная разность и будет отражать число совпадающих рангов. Отрицательная разность приравнивается к нулю, поскольку в том случае совпадающих рангов нет.

5. Расчет коэффициента корреляции τ - Кендалла используя упрощенную формулу (2).

6. Определение уровня значимости коэффициента.

Для того чтобы при уровне значимости α проверить нулевую гипотезу о равенстве нулю генерального коэффициента ранговой корреляции Кендалла при конкурирующей гипотезе $H_1: \tau \neq 0$, надо вычислить критическую точку:

$$T_{kp} = z_{kp} \sqrt{\frac{2(2n+5)}{9n(n-1)}}, \quad (3)$$

где n – объем выборки; z_{kp} – критическая точка двусторонней критической области, которую находят по таблице функции Лапласа по равенству:

$$\Phi(Z_{kp}) = \frac{(1-\alpha)}{2}. \quad (4)$$

1. Сопоставление значения коэффициента ранговой корреляции τ -Кендалла и уровня его значимости.

Если $|\tau| < T_{kp}$ – нет оснований отвергнуть нулевую гипотезу. Ранговая корреляционная связь между качественными признаками незначима. Если $|\tau| > T_{kp}$ – нулевую гипотезу отвергают. Между качественными признаками существует значимая ранговая корреляционная связь.

2. Оповещение администратора ВП об аномалии если, если сила корреляционной связи слабая ($< 0,3$);

На практике, если взаимосвязь между суммарным временем отклика и количеством обработанных транзакций пользователя стабильно удерживается, то корреляционная связь высокая. Ослабление силы связей между суммарным временем отклика и количеством обработанных транзакций пользователя, дает основание предполагать о возможной аномалии в производительности ВП.

7. Имитационное моделирование. Анализ результатов

Имитационная модель состоит из нескольких уровней инфраструктуры, а именно:

- веб-приложения JPetStore6 [9], которое реализует прототип электронного магазина с основными функциями покупки-продажи товаров;

- нагрузочного приложения TPC-W [10], основная задача которого заключается в имитации активности в магазине. Приложение позволяет эмулировать несколько одновременных сессий пользователей, покупку разных товаров в один момент времени и тд;

- базы данных MySQL [11] для хранения данных мониторинга;

- инструменты мониторинга на уровне приложения, а именно: jeeObserver [12], InfraRED [13], JavaMelody [14]. С их помощью были собраны метрики необходимые для анализа;

- модуль анализа данных мониторинга с помощью КРК Кендалла. Цель данного модуля заключается в определении аномалии производительности ВП, на основе оценки силы корреляционной связи между значениями;

- модуль электронного оповещения администратора ВП в случае возникновения аномалии.

Имитационное моделирование проходило по следующему сценарию: с помощью нагрузочного приложения TPC-W была с эмулирована активность на веб-приложении JPetStore6, далее с помощью инструментов мониторинга jeeObserver, InfraRED, JavaMelody были собраны метрики необходимые для анализа и сохранены в БД. После этого данные мониторинга были проанализированы и определены силы корреляционной связи между значениями, на основе которых, были детерминированы аномалии в производительности ВП.

Имитационное моделирование учитывает разное время отклика сервера на пользовательские транзакции и разное количество пользовательских транзакций. Для анализа были использованы 10 пар значений X и Y с учетом увеличения задержки времени отклика сервера на данные транзакции.

В табл. 1, 2 представлены фактические значения величин, полученные в результате мониторинга, а также предварительный анализ входящих данных для определения КРК Кендалла. Рассмотрим данные результаты подробнее, используя технику обнаружения аномалий, изложенную выше.

По формуле (2) вычислим коэффициент ранговой корреляции τ -Кендалла:

$$\tau = 0.82$$

Далее нужно определить уровень значимости полученного коэффициента, для этого необходимо вычислить критическую точку, по формулам (4,3), где

$$\Phi(Z_{kp}) = 0,3,$$

$$T_{kp} = 0,21.$$

Так как $|\tau| > T_{kp}$ – ранговая корреляционная связь между оценками по двум тестам значимая. На основании этого делаем вывод, что аномалии в производительности не обнаружены.

Однако, в табл. 2 приведены величины, между которыми корреляционная связь не значимая, что дает основания полагать о возникновении аномалии в производительности ВП.

Таблица 1

Результаты моделирования при сильной корреляционной связи

Задержка времени отклика (мсек), X	Количество обработанных транзакций, Y	ранг X , d_x	ранг Y , d_y	P
200	10	1	1	9
265	12	2	2	8
287	13	3	3	7
345	14	4	4	6
354	17	5	6	4
365	23	6	9	1
458	16	7	5	3
654	18	8	7	2
743	19	9	8	1
873	30	10	10	0
				41

Таблица 2

Результаты моделирования при слабой корреляционной связи

Задержка времени отклика (мсек), X	Количество обработанных транзакций, Y	ранг X , d_x	ранг Y , d_y	P
654	18	1	9	1
765	10	2	5	4
1265	12	3	7	2
1345	6	4	3	4
1361	4	5	1	5
1365	5	6	2	4
1542	8	7	4	3
1845	10	8	6	2
2776	29	9	10	0
3458	16	10	8	0
				25

Также, как и в первом случае вычислим τ -Кендалла, который равен:

$$\tau = 0.11$$

И определим уровень значимости используя формулы (3,4):

$$\Phi(Z_{kp}) = 0,3,$$

$$T_{kp} = 0,21$$

Так как $|\tau| < T_{kp}$ – ранговая корреляционная связь между оценками по двум тестам незначимая. В данном случае корреляционная связь слабая, а значит существует вероятность аномалии в производительности приложения.

Анализируя величины с табл. 2, прослеживается взаимосвязь между задержкой времени отклика и уменьшением количества обработанных транзакций, что ведет к ослаблению корреляционной связи и возникновению аномалии в производительности. Аномалии обычно проявляются деградацией производительности для конечного пользователя и увеличивают время на выполнение заданных операций, по этому своевременное обнаружение и оповещение администратора ВП крайне важно.

8. Выводы

В данной статье описана и проанализирована техника обнаружения аномалий в производительности ВП с помощью коэффициента ранговой корреляции τ -Кендалла. Для анализа были взяты значения двух

метрик: суммарного времени отклика по транзакции пользователя и количества обработанных пользовательских транзакций за этот период. Далее с помощью КРК Кендалла была определена сила корреляционной связи между данными величинами с целью детерминировать аномалию в производительности ВП. Если сила связи слабая, то высока вероятность аномалии в производительности ВП, что также подтверждается имитационным моделированием. Данное утверждение справедливо и для данных с табл. 2, где с увеличением времени отклика и уменьшением количества обработанных транзакций сила корреляционной связи слабеет и увеличивается вероятность возникновения аномалии. Техника, описанная в данной статье, может помочь обнаружить аномалию производительности ВП по факту возникновения, но она не даст информации о том, где именно в исходном коде аномалия возникла и по какой причине.

Литература

1. Thomas, P. R. Modern engineering statistics [Text] / P. R. Thomas. – Wiley-Interscience, 1st edition, 2007. – 736 p. doi: 10.1002/9780470128442
2. Benesty, A. A. Pearson Correlation Coefficient [Text] / A. Benesty, A. Chen. – Springer Berlin Heidelberg, 2009. – 326 p.
3. Jerrold, H. Z. Significance Testing of the Spearman Rank Correlation Coefficient [Text] / H. Z. Jerrold // Journal of the American Statistical Association, 1972. – Vol. 67, Issue 339. – P. 578–580. doi: 10.2307/2284441
4. Харченко, М. А. Корреляционный анализ [Text] / М. А. Харченко, – Учебное пособие для вузов. – Воронеж: Изд-во ВГУ, 2008. – 31 с.
5. Magalhaes, J. P. Anomaly Detection Techniques for Web-Based Applications: An Experimental Study [Text] / J. P. Magalhaes, L. M. Silva // 11th IEEE International Symposium on Network Computing and Applications, 2012. – P. 181–190. doi: 10.1109/nca.2012.27
6. Kiczales, G. Aspect-Oriented Programming [Text] / G. Kiczales, J. Lamping, A. Mendhekar, C. Maeda, C. L. Videira, J. M. Loingtier, J. Irwin // In Proceedings of the 11th European Conference on Object Oriented Programming, 1997. – P. 220–242. doi: 10.1007/bfb0053381
7. Cherkasova, L. Anomaly? Application Change? or Workload Change? Towards Automated Detection of Application Performance Anomaly and Change [Text] / L. Cherkasova, K. M. Ozonat, M. Ningfang, J. Symons, E. Smirni // In Proceedings of the International Conference on Dependable Systems and Networks, 2008. – P. 452–461. doi: 10.1109/dsn.2008.4630116
8. Aguilera, M. K. Performance debugging for distributed systems of black boxes [Text] / M. K. Aguilera, J. C. Mogul, J. L. Wiener, P. Reynolds and A. Muthitacharoen, – In Proceedings of the nineteenth ACM symposium on Operating Systems Principles, 2003. – 74–89.
9. MyBatis – MyBatis-Spring Sample Code [Electronic resource] / Available at: <https://mybatis.github.io/spring/sample.html> – 18.01.2015. – Загл. с экрана.
10. TPC-W – Benchmarking an Ecommerce Solution [Electronic resource] / Available at: <http://www.tpc.org/tpcw/> – 18.01.2015. – Загл. с экрана.
11. MySQL: The World's Most Popular Open Source Database [Electronic resource] / Available at: <http://www.mysql.com/> – 18.01.2015. – Загл. с экрана.
12. jeeObserver. J2EE performance monitoring tool [Electronic resource] / Available at: <http://www.jeeobserver.com> – 18.01.2015. – Загл. с экрана.
13. InfraRED. Opensource J2EE Performance Monitoring Tool. [Electronic resource] / Available at: <http://infrared.sourceforge.net/> – 18.01.2015. – Загл. с экрана.
14. JavaMelody. Monitoring of JavaEE applications [Electronic resource] / Available at: <http://code.google.com/p/javamelody/> – 18.01.2015 г. – Загл. с экрана.

References

1. Thomas, P. R. (2007). Modern engineering statistics. Wiley-Interscience, 1st edition, 736. doi: 10.1002/9780470128442
2. Benesty, A. A. (2009). Pearson Correlation Coefficient. Springer Berlin Heidelberg, 326.
3. Jerrold, H. Z. (1972). Significance Testing of the Spearman Rank Correlation Coefficient. Journal of the American Statistical Association, 67 (339), 578–580. doi: 10.2307/2284441
4. Harchenko, M. A. (2008). Correlation analiz. Manual for students, 31.
5. Magalhaes, J. P., Silva, L. M. (2012). Anomaly Detection Techniques for Web-Based Applications: An Experimental Study. In Proceedings of the 11th IEEE International Symposium on Network Computing and Applications, 181–190. doi: 10.1109/nca.2012.27
6. Kiczales, G., Lamping, J., Mendhekar, A., Maeda, C., Videira, C. L., Loingtier, J. M., Irwin, J. (1997). Aspect-Oriented Programming. In Proceedings of the 11th European Conference on Object Oriented Programming, 220–242. doi: 10.1007/bfb0053381
7. Cherkasova, L., Ozonat, K. M., Ningfang, M., Symons, J., Smirni, E. (2008). Anomaly? Application Change? or Workload Change? Towards Automated Detection of Application Performance Anomaly and Change. In Proceedings of the International Conference on Dependable Systems and Networks, 452–461. doi: 10.1109/dsn.2008.4630116
8. Aguilera, M. K., Mogul, J. C., Wiener, J. L., Reynolds, P., Muthitacharoen, A. (2003). Performance debugging for distributed systems of black boxes. In Proceedings of the nineteenth ACM symposium on Operating Systems Principles, 74–89.
9. MyBatis – MyBatis-Spring Sample Code. Available at: <https://mybatis.github.io/spring/sample.html>
10. TPC-W: Benchmarking an Ecommerce Solution. Available at: <http://www.tpc.org/tpcw/>
11. MySQL : The World's Most Popular Open Source Database. Available at: <http://www.mysql.com/>
12. jeeObserver. J2EE performance monitoring tool. Available at: <http://www.jeeobserver.com/>
13. InfraRED. Opensource J2EE Performance Monitoring Tool. Available at: <http://infrared.sourceforge.net/>
14. JavaMelody. Monitoring of JavaEE applications. Available at: <http://code.google.com/p/javamelody/>

*Рекомендовано до публікації д-р техн. наук Первунінський С. М.
Дата надходження рукопису 27.01.2015*

Сытник Антон Александрович, аспирант, кафедра программного обеспечения автоматизированных систем, Черкасский государственный технологический университет, бул. Шевченка, 460, г. Черкасы, Украина, 18000,
E-mail: sytnik.anton@gmail.com