



Інтелектуальна система прогнозування зниження продуктивності віртуальних машин у середовищі хмарних обчислень

В. В. Москаленко¹⁾, С. В. Пімоненко²⁾

^{1), 2)} Сумський державний університет, вул. Римського-Корсакова, 2, м. Суми, Україна, 40007

Article info:

Paper received:

17 May 2015

The final version of the paper received:

24 November 2015

Paper accepted online:

30 November 2015

Correspondent Author's Address:

¹⁾ systemscoders@gmail.com

У статті в рамках інформаційно-екстремальної інтелектуальної технології розглядається аналіз та синтез системи прогнозування зниження продуктивності віртуальних машин на спільній фізичній інфраструктурі внаслідок їх конкуренції за ресурси. Запропоновано формування вхідного математичного опису системи шляхом кластер-аналізу метрик продуктивності віртуальних машин та метрик використання ресурсів. Як ознаки розпізнавання стану зниження продуктивності системи розглядаються кількість розміщених на хості віртуальних машин кожного класу споживання ресурсів та обсяг вільних ресурсів процесора, оперативної та дискової пам'яті і мережевого каналу. Розроблені алгоритми ґрунтуються на адаптивному двійковому кодуванні ознак розпізнавання та оптимізації геометричних параметрів розбиття простору ознак на класи еквівалентності у процесі максимізації інформаційної спроможності системи оцінювання функціонального стану обчислювального середовища. Як критерій оптимізації запропоновано використовувати модифікацію інформаційної міри Кульбака, що є функціоналом від помилки другого роду та першої достовірності прийняття рішень.

Ключові слова: віртуальна машина, хмарні обчислення, машинне навчання, клас розпізнавання, словник ознак, інформаційний критерій, прогнозування, оптимізація.

ВСТУП

Провайдери хмар використовують технології віртуалізації, які дозволяють розділяти ресурси фізичних машин між багатьма віртуальними машинами, що належать різним арендаторам. Сумісне користування ресурсами сприяє підвищенню ефективності використання хмарної IT-інфраструктури і скороченню витрат на обслуговування. При цьому надання хмарних послуг може бути реалізоване відповідно до однієї з бізнес-моделей – оплата в міру споживання (Pay as you go) або передплата зарезервованих ресурсів (Reservation Pool). Система керування хмарною інфраструктурою повинна забезпечувати якість обслуговування (Quality of Service) клієнтів, хмари та максимізацію використання введеніх до експлуатації ресурсів. Рівень якості обслуговування залежить від своєчасності реагування на запити додаткових ресурсів та на ознаки зниження продуктивності додатків, що розміщені на віртуальних машинах. Зменшення простою ресурсів пов'язане як із реалізацією оверселінгу (Overselling), що полягає у перепродажі нездійнях (проте зарезервованих) ресурсів, так і з динамічною оптимізацією розміщення віртуальних машин [1-3]. При цьому система керування IT-інфраструктурою повинна вирішувати завдання енергозбереження шляхом розвантаження і вимкнення живлення слабозавантажених фізичних машин та попередження зниження продуктивності віртуальних машин, що розміщені на хостовому сер-

вері з високим рівнем утилізації ресурсів. Основною причиною зниження продуктивності віртуальних машин, що працюють на спільній інфраструктурі апаратного забезпечення, є їх недостатня ізоляція. Ефект змагання віртуальних машин за різні фізичні ресурси ще називають «інтерференцією». Інтереференція виникає на рівні апаратних компонентів, таких як процесори, пам'ять, засоби введення - виведення та мережевий канал, і підсилюється їх спільним впливом [3, 4]. Прогнозування зниження продуктивності віртуальних машин дозволяє підтримувати заданий рівень обслуговування SLA (Service Level Agreement) шляхом врахування відповідної інформації при міграції існуючих чи розміщені нових віртуальних машин на фізичних хостових серверах. Повторюваний характер завдань, що вирішуються додатками віртуальних машин, забезпечує можливість застосування методів машинного навчання для аналізу log-даних трасування роботи віртуальних машин і синтезу моделі прогнозування рівня їх інтерференції. Проте багатовимірність спостережень за функціональним станом гетерогенного обчислювального середовища обумовлює перетин класів розпізнавання в просторі ознак і невисоку достовірність вирішальних правил, одержаних за допомогою традиційних методів аналізу даних.

Мета статті – запропонувати в рамках інформаційно-екстремальної інтелектуальної технології метод інформаційного синтезу високодостовірних ви-

рішальних правил для прогнозування рівнів інтерференції віртуальних машин при різних комбінаціях їх розміщення на фізичних серверах.

ПОСТАНОВКА ЗАДАЧІ

Нехай подано апріорно некласифікований набір векторів спостереження за роботою віртуальних машин $\{v_i^{\theta} \mid j = \overline{1, n}; i = \overline{1, N}\}$ та алфавіт класів споживання ресурсів $\{T_k^o \mid k = \overline{1, K}\}$, що характеризує типи задач, які вирішуються на основі цих віртуальних машин. При цьому клас T_1^o є базовим і відповідає мінімальному рівню споживання ресурсів пам'яті, процесора та каналу мережі. Для різних варіантів комбінації розміщення віртуальних машин, що належать до різних класів споживання ресурсів $\dots \mid k = \overline{1, K}$, на фізичних серверах задано алфавіт образів $\{I_c^o \mid c = \overline{1, C}\}$, що характеризує рівень інтерференції віртуальних машин на спільній апаратній інфраструктурі, і відповідну апріорно класифіковану навчальну матрицю типу об'єкт-властивість $\{y_{c,i}^{\theta} \mid j = \overline{1, n}; i = \overline{1, N}; c = \overline{1, C}\}$. Клас I_1^o є базовим і відповідає нульовому рівню інтерференції. Відома структура вектора параметрів функціонування системи прогнозування рівня інтерференції:

$$g = \langle \delta_{T,i}, \delta_{I,i}, x_m, d_m \rangle, \quad (1)$$

де $\delta_{T,i}, \delta_{I,i}$ – параметри поля контрольних допусків для i -ї ознаки класифікаторів віртуальних машин (за ознаками споживання ресурсів) та рівня інтерференції відповідно; x_m – двійковий еталонний вектор класу $X_m^o \in \{T_k^o\} \cup \{I_c^o\}$, що визначає геометричний центр його гіперсферичного контейнера; d_m – кодовий радіус контейнера класу $X_m^o \in \{T_k^o\} \cup \{I_c^o\}$, що побудований в радіальному базисі бінарного простору ознак.

При цьому задано такі обмеження: $d(x_m \oplus x_{cm}) > d_m$, де $d(x_m \oplus x_{cm})$ – кодова відстань між двійковим еталонним вектором класу X_m^o та двійковим еталонним вектором сусіднього до нього класу X_{cm}^o ; $\delta_{T,i} \in [0; \delta_{\max}]$, $\delta_{I,i} \in [0; \delta_{\max}]$.

Необхідно в процесі навчання системи прогнозування рівня інтерференції визначити оптимальні значення координат вектора параметрів функціонування g^* (1), що забезпечують максимальне значення усередненого за алфавітом класів розпізнавання інформаційного КФЕ:

$$\bar{E} = \frac{1}{M} \sum_{m=1}^M \max_{G_E} \{E_m\}. \quad (2)$$

Необхідно в робочому режимі системи прогнозування рівня інтерференції прийняти рішення про належність розміщених на фізичному сервері віртуальних машин до відповідних класів споживання ресурсів з алфавіту $\{T_k^o\}$ та про відповідність даної

комбінації розміщення віртуальних машин одному з класів алфавіту рівнів інтерференції $\binom{o}{c}$.

АЛГОРИТМ ФУНКЦІОНАВАННЯ СИСТЕМИ ПРОГНОЗУВАННЯ ЗНИЖЕННЯ ПРОДУКТИВНОСТІ ВІРТУАЛЬНИХ МАШИН

Навчання системи прогнозування рівнів інтерференції за даними трасування роботи віртуальних машин запропоновано починати з формування в процесі кластер-аналізу алфавіту класів віртуальних машин залежно від їхнього середнього рівня споживання різного типу фізичних ресурсів. При цьому словник ознак класифікатора віртуальних машин повинен включати середній обсяг використання ресурсу процесорів, оперативної пам'яті, файла підкачування, мережевого каналу, дискового простору, середню інтенсивність операцій введення-виведення з дисковою пам'яттю. На другому етапі необхідно в процесі кластер-аналізу сформувати алфавіт рівнів інтерференції, де словник ознак включає записи про зміну у відсотках сумарного споживання різного типу ресурсів, зміну метрик продуктивності, відсоток помилок обробки задач на віртуальній машині, відсоток часу перебування процесора в стані блокування та інші зміни, викликані розміщенням нової віртуальної машини. Наступний крок аналізу даних передисторії полягає у з'язуванні кожної знайденої комбінації розміщення віртуальних машин на фізичних серверах із відповідним класом рівня інтерференції $\binom{o}{c}$. Як ознаки можна розглядати кількість розміщених на хості віртуальних машин кожного класу T_k^o та метрики споживання ресурсів процесора, оперативної та дискової пам'яті і мережевого каналу.

Оптимізація геометричних параметрів вирішальних правил, що формуються у процесі інформаційно-екстремального кластер-аналізу спостережень за споживанням ресурсів і продуктивністю віртуальних машин, здійснюється в бінарному просторі вторинних ознак, переході до якого здійснюється в процесі адаптивного двійкового кодування первинних ознак розпізнавання [5, 6]. При цьому нижня $A_{H,i}$ та верхня $A_{B,i}$ межі поля контрольних допусків для i -ї ознаки обчислюються за формулами:

$$A_{H,i} = y_{\max,i} - \delta_i, \quad A_{B,i} = y_{\max,i}, \quad (3)$$

де $y_{\max,i}$ – максимальне значення обсягу використання i -го ресурсу віртуальною машиною в архівних даних моніторингу.

В алгоритмі інформаційно-екстремального машинного навчання з учителем, що призначений для формування вирішальних правил прогностичного класифікатора рівнів інтерференції межі поля контрольних допусків для i -ї ознаки обчислюються за такими формулами:

$$A_{H,i} = \overline{y_{1,i}} - \delta_i, \quad A_{B,i} = \overline{y_{1,i}} + \delta_i, \quad (4)$$

де $\overline{y_{1,i}}$ – середнє значення i -ї ознаки в базовому класі.

Кодування ознак полягає у порівнянні їх числових значень $y_{m,i}^{(j)}$ з верхнім $A_{B,i}$ та нижнім $A_{H,i}$ порогами і формуванні навчальної матриці вторинних (бінарних) ознак $\{x_{m,i}^{(j)} | i = \overline{1, N}; j = \overline{1, n}; m = \overline{1, M}\}$ за правилом

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } A_{H,i} \leq y_{m,i}^{(j)} \leq A_{B,i}; \\ 0, & \text{else.} \end{cases} \quad (5)$$

Розглянемо основні етапи реалізації алгоритму інформаційно-екстремальної кластеризації даних моніторингу на М кластерів.

1. Формування множини двійкових векторів $\{x'^{(z)} | z = \overline{1, n'}\}$, що є потенційними початковими центрами контейнерів, шляхом копіювання двійкової матриці $\{x_i^{(j)}\}$, видалення в ній однакових векторів та сортування решти векторів у порядку збільшення кількості одиничних координат.

2. Формування початкових центрів контейнерів $\{x_m | m = \overline{1, M}\}$ за правилом

$$x_m = \begin{cases} x'^{(1)}, & m = 1; \\ x'^{(n' \cdot [m-1]/[M-1])}, & 1 < m < M; \\ x'^{(n')}, & m = M. \end{cases} \quad (6)$$

3. Кластер-аналіз двійкової матриці класу $\{x_i^{(j)}\}$ за алгоритмом k-середніх [7] з використанням дистанційної міри Хеммінга та формування множини оптимальних центрів кластерів x_m^* .

4. Оптимізація радіуса контейнерів здійснюється за процедурою

$$d_m^* = \arg \max_{G_d \cap G_n} \{\bar{E}\}, \quad (7)$$

де $G_d \in [0; d(x_m^* \oplus x_c) - 1]$ – область допустимих значень параметра d_m , що обмежена міжцентральною кодовою відстанню $d(x_m^* \oplus x_c)$ до найближчого сусіднього кластера (класу) X_c^o ; $G_n \in [80\%; 100\%]$ – область допустимих значень відсотка кластеризованих (охоплених контейнерами) векторів-реалізацій від загального обсягу.

Оптимізація параметра $\delta = \delta_i, i = \overline{1, N}$ рецептивного поля, що реалізує механізм адаптивного двійкового кодування ознак, здійснюється за ітераційною процедурою [5, 6]

$$\delta^* = \arg \max_{G_\delta} \left\{ \frac{1}{M} \sum_{s=1}^M \left[\max_{G_E \cap G_d} E_m \right] \right\}, \quad (8)$$

де G_δ – область допустимих значень параметра рецептивного поля; G_E – допустима область визначення функції критерію (1), що обмежена нерівностями $D_{1,m} \geq 0,5$ і $D_{2,m} \geq 0,5$; E_m – критерій ефективно-

сті навчання класифікатора розпізнавати реалізації m -го класу.

Як критерій ефективності навчання (кластер-аналізу) розглядається модифікація інформаційної міри Кульбака [6], в якій відношення правдоподібності подане у вигляді відношення повної ймовірності правильного прийняття рішень P_{true} до повної ймовірності помилкового прийняття рішень P_{false} . Для випадку двох альтернативних і рівномірних гіпотез міра Кульбака має вигляд

$$J_m = \left[P_{true,m} - P_{false,m} \right] \log_2 \frac{P_{true,m}}{P_{false,m}} = \begin{cases} P_{true,m} = 0,5D_{1,m} + 0,5D_{2,m} \\ P_{false,m} = 0,5\alpha_m + 0,5\beta_m \\ \alpha_m = 1 - D_{1,m}; D_{2,m} = 1 - \beta_m \end{cases} = \left[D_{1,m} - \beta_m \right] * \log_2 \left(\frac{1 + [D_{1,m} - \beta_m]}{1 - [D_{1,m} - \beta_m]} \right), \quad (9)$$

де $D_{1,m}$ – перша достовірність для класу X_m^o ; $D_{2,m}$ – друга достовірність; α_m – помилка другого роду; β_m – помилка другого роду.

Для порівняльного аналізу результатів досліджень і під час оцінювання ступеню близькості реальної системи до потенційної доцільно використовувати нормовану модифікацію критерію, що подають у вигляді [5]:

$$E_m = \frac{J_m}{J_{max}}, \quad (10)$$

де J_{max} – значення критерію при $D_{1,m} = 1$ та $\beta_m = 0$.

У режимі екзамену рішення про належність вектора-реалізації $x^{(j)}$ одному з класів алфавіту $\{X_m^o\}$ приймається шляхом обчислення геометричної функції належності

$$\mu_m = 1 - \frac{d(x_m^* \oplus x^{(j)})}{d^*}, \quad (11)$$

де $d(x_m^* \oplus x^{(j)})$ – кодова відстань від еталонного вектора (центра контейнера) класу X_m^o до вектора $x^{(j)}$.

Таким чином, у процесі інформаційно-екстремального кластер-аналізу формується вхідний математичний опис для здатної навчатися системи прогнозування рівня інтерференції віртуальних машин на фізичному сервері хмарної інфраструктури. При цьому параметри функціонування прогностичного класифікатора визначаються шляхом ітераційної процедури пошуку глобального максимуму інформаційного критерію за Кульбаком у допустимій області визначення його функції.

РЕЗУЛЬТАТИ ФІЗИЧНОГО МОДЕЛЮВАННЯ

Розглянемо використання запропонованих алгоритмів на реальних даних моніторингу роботи хмарної інфраструктури. Для формування вхідного математичного опису системи прогнозування рівня інтерференції віртуальних машин було взято дані трасування роботи центрів обробки великих даних, що опубліковано компанією Google в 2011 році [8]. При цьому для формування вибірки спостережень, що відповідають різним рівням «інтерференції» віртуальних машин, фіксувалися такі події: задача спрямована планувальником на хостову машину для запуску; для завдання виконується перепланування (міграція); завдання виконане успішно. На основі цих подій визначалися моменти часу для розрахунку зміни метрик використання ресурсів і продуктивності відповідних віртуальних машин унаслідок конкуренції за ресурси. Ці самі моменти подій використовуються для зв'язування комбінацій розміщення віртуальних машин, які зустрічаються в передисторії, з відповідним рівнем інтерференції.

На рисунку 1 показано результати оптимізації кількості класів споживання ресурсів та класів інтерференції, що здійснюється у процесі інформаційно-екстремального кластер-аналізу спостережень за споживанням ресурсів та спостережень за змінами споживання і продуктивності. Обсяг апріорно некласифікованих вибірок становить $n=1000$. При цьому за оптимальне значення кількості кластерів обирається те найбільше значення, яке забезпечує найбільш чітке розбиття простору ознак.

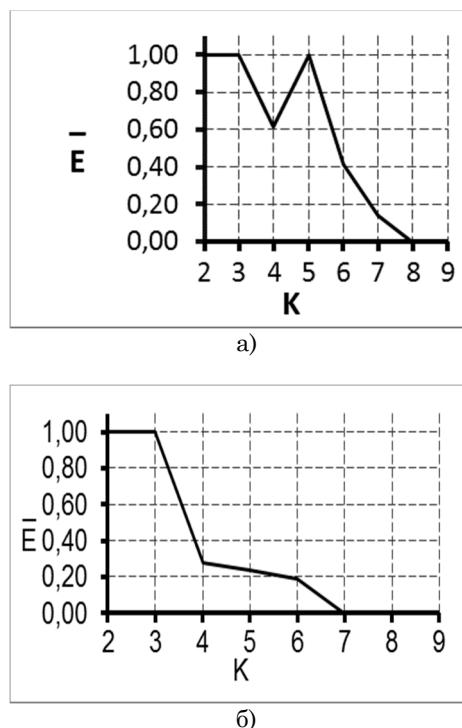


Рисунок 1 – Графік залежності усередненого нормованого інформаційного КФЕ від заданої кількості кластерів розбиття: а) на класи споживання ресурсів; б) на класи рівня інтерференції

Аналіз рис. 1 показує, що при обраному словнику ознак і обраній процедурі кодування ознак (3) оптимальна в інформаційному сенсі кількість класів споживання ресурсів віртуальної машини становить $K^*=5$. Оптимальна в інформаційному сенсі кількість класів інтерференції – $C^*=3$.

Наступним етапом є підрахунок кількості віртуальних машин кожного класу та обчислення усереднених значень обсягу споживання різного типу ресурсів на хостових машинах з метою формування вхідного математичного опису для прогностичного класифікатора рівнів інтерференції. Обсяг вибірок кожного класу в навчальній матриці становить $n_c=70$.

На рисунку 2 показано графіки залежності нормованого критерію Кульбака (6) від параметрів поля контрольних допусків δ_T та δ_I , одержаних у процесі навчання прогностичної системи за процедурою (4). На графіку (тут і далі) затемнена ділянка позначає робочу область визначення функції інформаційного критерію.

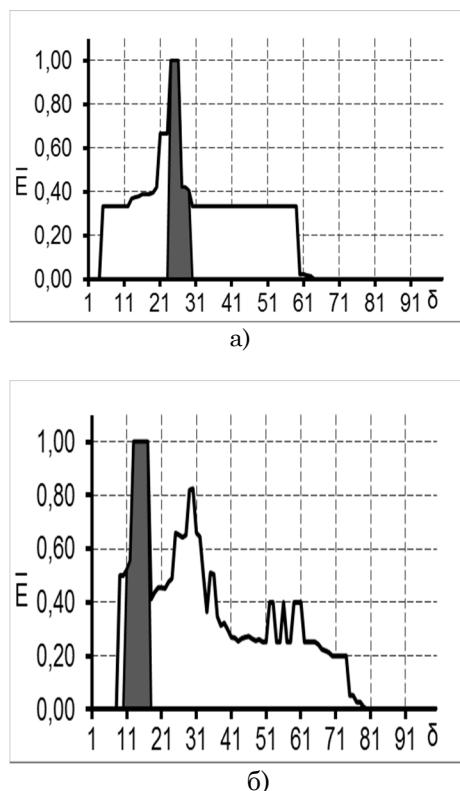


Рисунок 2 – Графік зміни усереднено нормованого КФЕ при оптимізації параметра поля контрольних допусків: а) параметр δ_T ; б) параметр δ_I

Аналіз рис. 2 показує, що оптимальний параметр поля контрольних допусків на значення ознак класу споживання ресурсів дорівнює $\delta_T^*=\pm 67\%$ при значенні максимуму усередненого критерію $\bar{E}^*=1,0$.

Аналіз рис. 2б показує, що оптимальний параметр поля контрольних допусків на значення ознак класу ступеня інтерференції дорівнює $\delta_I^*=\pm 35\%$ при значенні максимуму усередненого критерію $\bar{E}^*=1,0$. Оскільки метою інформаційно-екстремального на-

вчання є відновлення в просторі ознак оптимальних контейнерів класів розпізнавання, то на рис. 3 наведено графіки залежності нормованого КФЕ (6) від радіусів контейнерів класів I_1^o , I_2^o та I_3^o .

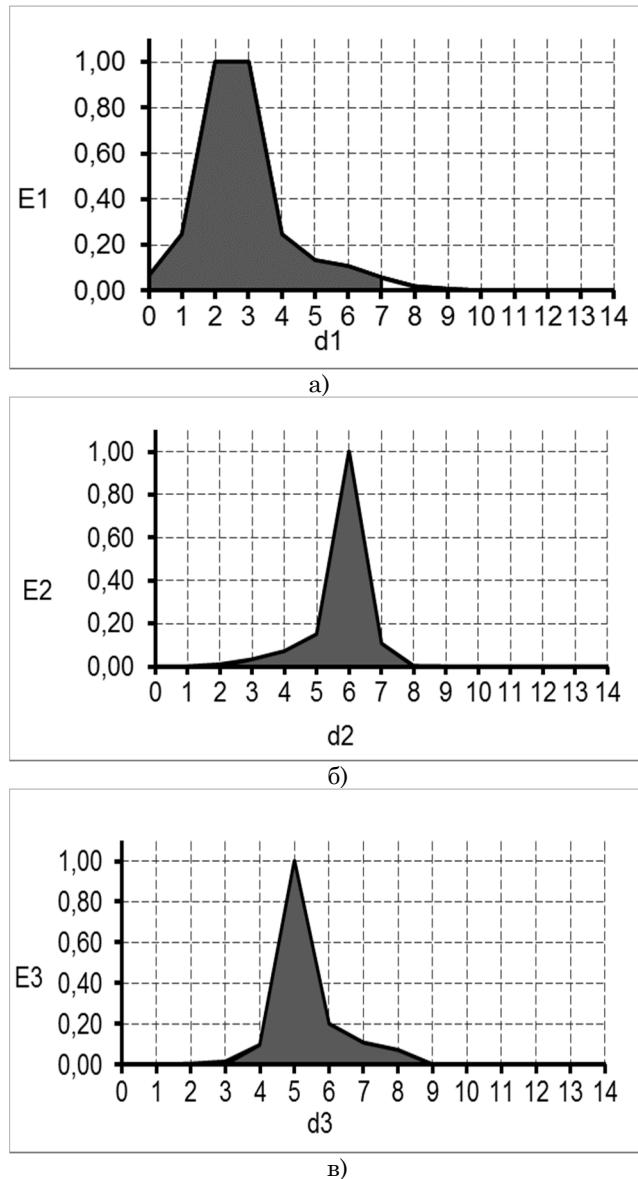


Рисунок 3 – Залежність КФЕ (6) від радіуса контейнера класу рівня інтерференції: а) клас I_1^o ; б) клас I_2^o ; в) клас I_3^o

Аналіз рис. 3 показує, що оптимальні значення радіусів гіперсферичних контейнерів класів I_1^o , I_2^o та I_3^o відповідно дорівнюють: $d_1=15$, $d_2=31$ та $d_3=31$ (у кодових одиницях). При цьому вдалося побудувати безпомилкові за навчальною матрицею вирішальні правила.

Таким чином, на прикладі центрів обробки великих даних здійснено синтез безпомилкових за навчальною матрицею інформаційно-екстремальних вирішальніх правил для передбачення зниження продуктивності віртуальних машин внаслідок їх конкуренції за ресурси на хостових серверах хмарної інфраструктури.

ВИСНОВКИ

Отже, розроблений інформаційно-екстремальний алгоритм машинного навчання дозволяє одержати безпомилкові за навчальною матрицею вирішальні правила для передбачення конкуренції за ресурси віртуальних вузлів обробки великих даних.

Практична цінність одержаних результатів для хмарних обчислень полягає у формуванні інструменту попередження зниження продуктивності віртуальних машин у процесі оптимізації енерговитрат і підтримці заданого рівня обслуговування для користувачів хмарних сервісів.

Intelligent system for predict performance degradation of virtual machines in cloud environment

V. V. Moskalenko¹⁾, S. V. Pimonenko²⁾

^{1), 2)} Sumy State University, 2, Rimsky Korsakov Str., 40007, Sumy, Ukraine

In this article the information-extreme intellectual technologies of analyzing and synthesis of the forecasting system are researched. In this case the authors analyzed the degradation of the virtual machines owing to their interference on a common physical infrastructure. The authors proposed the approaches of the formation the input of the mathematical description which based on the cluster-analysis of the performance and resource usage metrics of the virtual machines. Considered feature set for recognize a condition of performance degradation includes the amount of allocated to host virtual machines

from each resource consumption class, the amount of available CPU, RAM and disk space and network channel. The algorithms are based on adaptive binary coding of feature vectors and optimization of geometrical parameters of feature space partition into classes equivalence to maximize the information ability of system intended to predict functional state of the computing environment. The modified information criterion for estimate efficiency of machine learning is expressed in terms of false omission rate and positive predictive value. The physical modeling of proposed algorithms are implemented by the example of cloud services from Google.

Keywords: virtual machine, cloud computing, machine learning, set of classes, feature set, container of class, information criterion, prediction, optimization.

Интеллектуальная система прогнозирования снижения производительности виртуальных машин в среде облачных вычислений

Б. В. Москаленко¹⁾, С. В. Пимоненко²⁾

^{1), 2)} Сумський державний університет, вул. Римського-Корсакова, 2, г. Суми, Україна, 40007

В статье в рамках информационно-экстремальной интеллектуальной технологии рассматривается анализ и синтез системы прогнозирования снижения производительности виртуальных машин на совместной физической инфраструктуре в результате их конкуренции за ресурсы. Предложено формирование входного математического описания системы путем кластер-анализа метрик производительности виртуальных машин и метрик использования ресурсов. В качестве признаков распознавания состояния снижение производительности системы рассматриваются количество размещенных на хосте виртуальных машин каждого класса потребления ресурсов и объем свободных ресурсов процессора, оперативной и дисковой памяти и сетевого канала.

Разработанные алгоритмы основываются на адаптивном двоичном кодировании признаков распознавания и оптимизации геометрических параметров разбиения пространства признаков на классы эквивалентности в процессе максимизации информационной способности системы оценки функционального состояния вычислительной среды. В качестве критерия оптимизации предложено использовать модификацию информационной меры Кульбака, что является функционалом от ошибки второго рода и первой достоверности принятия решений.

Ключевые слова: виртуальная машина, облачные вычисления, машинное обучение, класс распознавания, словарь признаков, информационный критерий, прогнозирование, оптимизация.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Amannejad A. Detecting Performance Interference in Cloud-Based Web Services / Y. Amannejad, D. Krishnamurthy, B. Far // International Symposium on Integrated Network Management. – 2015. – Ottawa, ON : IEEE Press. – P. 423 – 431.
2. Dupont C. An Energy Aware Framework for Virtual Machine Placement in Cloud Federated Data Centres / C. Dupont, G. Giuliani, F. Hermenier // Proceedings of the 3rd International Conference on Future Energy Systems: Where Energy, Computing and Communication Meet. – 2012. – No. 4. – New York, NY, USA : ACM. – 10 p.
3. CloudScale: Elastic Resource Scaling for Multi-Tenant Cloud Systems / Z. Shen, S. Subbiah, X. Gu // Symposium on Cloud Computing. – 2011. – New York, NY, USA : ACM. – 14 p.
4. Yang Z. Understanding the Effects of Hypervisor I/O Scheduling for Virtual Machine Performance Interference / Z. Yang, H. Fang, Y. Wu, C. Li, B. Zhao, H.H. Huang // 4th International Conference on Cloud Computing Technology and Science. – 2012. – IEEE Press. – P. 34 - 41.
5. Moskalenko V. V. Information-Extreme Algorithm for Optimizing Parameters of Hyperellipsoidal Containers of Recognition Classes / A. S. Dovbysh, N. N. Budnyk, V. V. Moskalenko // Journal of automation and information sciences. – New York : Begell House Inc. – 2012. – V.44, I.10. – P. 35 - 44.
6. Dovbush A. S. Information-extreme algorithm for estimation of telecommunication GRID-system nodes / A. S. Dovbush, V. V. Moskalenko // Microwave and Telecommunication Technology (CriMiCo), 22nd International Crimean Conference. – 2012. – IEEE Press. – P.415 - 416.
7. Anderson B. J. Adapting K-Medians to Generate Normalized Cluster Centers / J. B. Anderson, D. S. Gross, D. R. Musicant, A. M. Ritz, T. G. Smith, L. E. Steinberg // Proceedings of the Sixth SIAM International Conference on Data Mining. – 2006. – Philadelphia : University City Science Center. – Pp. 165 - 175.
8. Liu Z. Characterizing Machines and Workloads on a Google Cluster / Z. Liu, S. Cho // 41st International Conference on Parallel Processing Workshops (ICPPW). – 2012. – IEEE Press. – P. 397 – 403.

REFERENCES

- H
1. Amannejad A., Amannejad Y., Krishnamurthy D., et al. (2015). Detecting Performance Interference in Cloud-Based Web Services. 2015 IFIP/IEEE International Symposium on Integrated Network Management (IM).
 2. Dupont C., Giuliani G., Hermenier F. (2012). An Energy Aware Framework for Virtual Machine Placement in Cloud Federated Data Centres. Proceedings of the 3rd

- International Conference on Future Energy Systems: Where Energy, Computing and Communication Meet. (p. 10).
3. Shen Z., Subbiah S., Gu X. (2011). CloudScale: Elastic Resource Scaling for Multi-Tenant Cloud Systems. Proceedings of the 2nd ACM Symposium on Cloud Computing. (p. 14)
 4. Yang Z., Fang H., Wu Y., et al. (2012). Understanding the Effects of Hypervisor I/O Scheduling for Virtual Machine Performance Interference. Proceedings of 4th International Conference on Cloud Computing Technology and Science. (pp. 34 - 41).
 5. Moskalenko V.V., Dovbysh A.S., & Budnyk N.N., (2012). Information-Extreme Algorithm for Optimizing Parameters of Hyperellipsoidal Containers of Recognition Classes. Journal of automation and information sciences, 44, 35 - 44.
 6. Dovbush A.S., Moskalenko V.V. (2012). Information-extreme algorithm for estimation of telecommunication GRID-system nodes. Proceedings of 22nd International Crimean Conference: Microwave and Telecommunication Technology (CriMiCo). (pp. 415 - 416).
 7. Anderson J.B., Gross D.S., Musicant D.R., et al. (2006). Steinberg Adapting K-Medians to Generate Normalized Cluster Centers. Proceedings of the Sixth SIAM International Conference on Data Mining. (pp. 165 - 175).
 8. Liu Z., Cho S. (2012). Characterizing Machines and Workloads on a Google Cluster. 41st International Conference on Parallel Processing Workshops (ICPPW). (pp. 397 – 403).