

Практическая значимость результатов исследования заключается в том, что использование результатов комплекса задач обеспечивает реальное повышение эффективности эксплуатации средств ЭХЗ магистральных газопроводов, позволяет сократить количество отказов трубопроводов и сократить затраты электроэнергии на УКЗ.

Литература

1. ДСТУ 4219:2003 Трубопроводи сталеві магістральні. Загальні вимоги до захисту від корозії

2. Бэкман В., Швенк В. Катодная защита от коррозии: Справ, изд. Пер. с нем. - М.: Металлургия, 1984. - 496 с.
3. СТП 320.30019801.072-2003 Магістральні газопроводи. Розрахунок електрохімічного захисту
4. Тевяшев А.Д., Ткаченко В.Ф., Попов А.В., Стрижак Л.В. Стохастический поход к постановке и решению задачи оперативного планирования режима работы системы ЭХЗ трубопровода //Восточно-Европейский журнал передовых технологий. 2005. №15 с. 94-98.

УДК 681.003.66

# МЕТОД ПОИСКА ЗАКОНОМЕРНОСТЕЙ В БАЗЕ ДАННЫХ ДИАГНОСТИЧЕСКОЙ ИНФОРМАЦИИ КОРПОРАТИВНОЙ IP-СЕТИ

*Дано опис метода діагностування корпоративної IP-мережі, в якому реалізована концепція інтелектуального аналізу даних. В якості джерела даних пропонується використовувати базу даних діагностичної інформації, яка містить опис роботи компонентів IP- мережі у вигляді набору подій*

*Ключові слова: IP-мережа, методи діагностики, асоціативні правила, інтелектуальний аналіз даних*

---

*Описан метод диагностирования корпоративной IP-сети, в котором реализована концепция интеллектуального анализа данных. В качестве источника данных предлагается использовать базу данных диагностической информации, которая содержит описания работы компонентов IP-сети в виде событий*

*Ключевые слова: IP-сеть, методы диагностики, ассоциативные правила, интеллектуальный анализ данных*

---

*The method of diagnostics of corporate IP networks, conception of intellectual analysis of data is realized in which, is described. As a source of data it is suggested to use the database of diagnostic information which contains descriptions of work of components of IP networks as events*

*Keywords: IP- networks, methods of diagnostics, associative rules, intellectual analysis of data*

**А. Л. Стокипный**

Офицер отдела

Восточное региональное управление Государственной пограничной службы Украины

г. Харьков

Контактный тел.: 8 (057) 700-92-06

E-mail – a.stokipny@gmail.com

## 1. Введение

На сегодняшний день в ходе создания подавляющего большинства современных корпоративных информационно-телекоммуникационных систем применяются IP-технологии и протоколы. Корпоративная IP-сеть является основой функционирования ключевых компонентов современных информационных

систем – пользовательских служб, распределенный характер которых выдвигает высокие требования к доступности используемой сети передачи данных. Повысить доступность корпоративной IP-сети можно путем сокращения времени простоя, составляющими которого с одной стороны является время, необходимое для проведения плановых работ по техническому обслуживанию, а с другой – время, затрачиваемое об-

служащим персоналом для восстановления работоспособного состояния корпоративной IP-сети после возникновения различного рода неисправностей. Применение резервирования отдельных компонентов IP-сети дает возможность сократить время простоя, однако является достаточно дорогостоящей процедурой. Наличие комплексной системы диагностики, в состав которой входят эффективные методы диагностирования, позволяет сократить время простоя корпоративной IP-сети, связанное с поиском причин возникновения неисправностей, их локализацией и проведением адекватных восстановительных мероприятий. Анализ литературы показал, что в ходе создания систем диагностики все чаще применяют подходы, основанные на знаниях [1,2,3]. Причем знания могут быть, как экспертного типа, так и полученные в ходе анализа баз данных диагностической информации (БДДИ), которые содержат описание работы компонентов IP-сети в виде значений диагностических параметров за длительный период времени. Целесообразность разработки систем диагностики, основанных на знаниях, подтверждаются также в ходе исследований, основным направлением которых является поиск методов автоматизации процесса создания и модификации базы знаний, сформированной на основе анализа диагностической информации [4,5,6].

**Целью статьи** будем считать разработку метода поиска закономерностей в БДДИ корпоративной IP-сети, который может быть в дальнейшем использован для создания и поддержки в актуальном состоянии базы знаний комплексной системы диагностики IP-сети.

## 2. Диагностическая модель корпоративной IP-сети

Предлагается формировать БДДИ корпоративной IP-сети в соответствии со следующей моделью:

$$M = \left\langle A \left\{ B_i \left\{ D_{ij} \left\{ e_{ij,k_{ij}} \right\}_{k_{ij}} \right\}_{j=1}^{J_i} \right\}_{i=1}^I \right\}, T, \Psi \right\rangle \quad (1)$$

где  $A$  – множество источников диагностической информации (ИДИ),  $|A|=I$ ;  $B_i$  – множества диагностических параметров ИДИ  $a_i$ ,  $|B_i|=J_i$ ;  $D_{ij}$  – множество интервалов, на которые разбита область значений параметра  $b_{ij}$ ,  $|D_{ij}|=K_{ij}$ ;  $e_{ij,k_{ij}}$  – событие, состоящее в принятии параметром  $b_{ij}$  значения из множества  $D_{ij,k_{ij}}$ ;  $T$  – моменты времени генерации событий  $e_{ij,k_{ij}}$  (опрос ИДИ и получение значений диагностических параметров);  $\Psi$  – упорядоченный набор записей вида  $\psi_p = (E_p, p)$ ;  $E_p$  – совокупность событий, сгенерированных в момент времени  $p \in T$ .

В качестве ИДИ мы будем рассматривать только те компоненты, которые предоставляют доступ к значениям диагностических параметров посредством протокола SNMP. Данное условие не сужает область применения модели (1), поскольку на сегодняшний день подавляющее большинство аппаратных и программных компонентов содержит реализацию указанного протокола.

Диагностические параметры (ДП) по характеру описания свойств компонентов и каналов передачи данных IP-сети можно классифицировать на общие и частные.

**Определение 1.** Частным диагностическим параметром (ЧДП) называется параметр, который отражает

индивидуальную характеристику отдельно взятого аппаратного или программного компонента.

Примерами частных параметров являются процент загрузки процессора, объем свободной оперативной памяти, количество пакетов, принятых с ошибками, количество открытых TCP соединений.

**Определение 2.** Общим диагностическим параметром (ОДП) называется параметр, который содержит агрегированную оценку функционирования системы взаимодействующих компонентов.

К классу общих относятся такие параметры, как время задержки доставки пакета, доступность службы, джиттер, время реакции при обращении к службе, скорость передачи данных.

IP-сеть обеспечивает работу множества служб  $S = \{s_1, s_2, \dots, s_l, l=1, L$ , где  $L$  – общее количество служб.

## 3. Методика определения состояния службы IP-сети

На основе данных технической документации и результатов наблюдения за процессом функционирования IP-сети, человек-эксперт может сформировать множество диагностических параметров  $V(s_l)$ , значения которых в дальнейшем необходимо учитывать в процессе идентификации состояния некоторой службы  $s_l$ . Если для всех служб известны множества  $V(s_l)$ , то для любого параметра  $b_{ij}$  можно определить множество  $S(b_{ij}) \in S$ . Служба  $s_l$  принадлежит множеству  $S(b_{ij})$  только при условии, что параметр  $b_{ij}$  используется в процессе определения ее состояния. Следует заметить, что правильность формирования  $V(s_l)$  и  $S(b_{ij})$  зависит, в первую очередь, от профессионального опыта, умения и навыков человека-эксперта.

**Определение 3.** Собственным параметром службы  $s_l$  называется диагностический параметр  $b_{ij}$ , на множестве значений  $D(b_{ij})$  которого задано разбиение  $D_{ij,k_{ij}^0}(b_{ij}) \cup D_{ij,k_{ij}^1}(b_{ij})$  такое, что значения из  $D_{ij,k_{ij}^0}(b_{ij})$  соответствуют работоспособному состоянию службы  $s_l$ , а значения из  $D_{ij,k_{ij}^1}(b_{ij})$  – неработоспособному.

**Определение 4.** Диагностический параметр не являющийся собственным параметром службы  $s_l$ , называется неопределенным параметром службы  $s_l$ .

Относительно элементов множества  $V(s_l)$  следует заметить, что использование их для идентификации состояния службы  $s_l$ , предполагает выполнение важного условия: для каждого параметра  $b_{ij} \in V(s_l)$  известны множества значений, которые он принимает в случае работоспособного и неработоспособного состояний службы  $s_l$ , следовательно, каждый из параметров  $b_{ij} \in V(s_l)$  является собственным параметром службы  $s_l$ .

**Определение 5.** Стандартным (номинальным) значением параметра  $b_{ij} \in V(s_l)$  относительно службы  $s_l$  называется значение, которое принимает параметр  $b_{ij} \in V(s_l)$  в случае, если служба  $s_l$  находится в работоспособном состоянии.

В модели (1) стандартные значения собственных диагностических параметров в обозначены как  $D_{ij,k_{ij}^0}(b_{ij})$ , а множество значений, соответствующих неработоспособному состоянию службы  $s_l$  – как  $D_{ij,k_{ij}^1}(b_{ij})$ .

Из определения неисправности в [7] следует, что под неисправностью следует понимать событие, при котором происходит недопустимое отклонение значений параметра системы от стандартного (номинального) значения. То есть событие  $e_{ij,k^1_{i_j}} \in E$ , состоящее в принятии параметром  $b_{ij} \in B(s_1)$  значения из множества  $D_{ij,k^1_{i_j}}(b_{ij})$ , является неисправностью и свидетельствует о факте перехода службы  $s_1$  в неработоспособное состояние. Следовательно, для некоторой службы  $s_1$  существует одно работоспособное состояние  $\Omega^p(s_1)$ , при котором значение любого из параметров  $b_{ij} \in B(s_1)$  принадлежит множествам  $D_{ij,k^0_{i_j}}(b_{ij})$ , и конечное множество неработоспособных состояний  $\Omega^{np}(s_1) = \left\{ \Omega_1^{np}(s_1), \Omega_2^{np}(s_1) \dots \Omega_{\tau_1}^{np}(s_1), \Omega_{N_{\tau_1}^{np}}^{np}(s_1) \right\}$ ,  $\tau_1 = \overline{1..N_{\tau_1}^{np}}$ , каждое из которых характеризуются наличием хотя бы одного параметра  $b_{ij} \in B(s_1)$  со значением, принадлежащим множеству  $D_{ij,k^1_{i_j}}(b_{ij})$ .

Общее количество неработоспособных состояний службы  $s_1$  равно  $N_{\tau_1}^{\Omega^{np}} = 2^{B(s_1)} - 1$ .

Расширим модель (1) и дополнительно введем обозначения:

$E^0(s_1)$  – совокупность вариантов формирования множества  $E_p(s_1)$ , при котором  $E_p(s_1)$  не содержит ни одной неисправности.

$E^1(s_1)$  – совокупность вариантов формирования множества  $E_p(s_1)$ , при которых  $E_p(s_1)$  содержит хотя бы одну неисправность.

$E^*(s_1) = E^0(s_1) \cup E^1(s_1)$  – совокупность всех возможных вариантов формирования множества  $E_p(s_1)$ .

Методику определения технического состояния некоторой службы  $s_1$  в терминах модели (1) определим следующим образом:

1. Задается множество собственных параметров  $B(s_1)$ , которые будут использоваться в процессе идентификации состояния  $s_1$ .

2. Для каждого  $b_{ij} \in B(s_1)$  на множестве значений  $D(b_{ij})$  определяется два подмножества таким образом, чтобы значения подмножества  $D_{ij,k^0_{i_j}}(b_{ij}) \subset D(b_{ij})$  соответствовали работоспособному состоянию службы  $s_1$ , а значения  $D_{ij,k^1_{i_j}}(b_{ij}) \subset D(b_{ij})$  – неработоспособному.

3. Формируется множество  $E^*(s_1)$  и выделяются его подмножества  $E^0(s_1)$  и  $E^1(s_1)$ . Исходя из того, что для идентификации состояния службы  $s_1$  используются только собственные параметры (этап 1) и каждый параметр идентифицирует два возможных состояния службы (этап 2), тогда множество  $E^0(s_1)$  содержит единственный элемент, который представляет собой совокупность событий  $e_{ij,k^0_{i_j}}$ .


4. Работоспособному состоянию  $\Omega^p(s_1)$  ставится в соответствие элемент множества  $E^0(s_1)$ .

5. Задается  $N_{\tau_1}^{\Omega^{np}} = |E^1(s_1)|$  доступных для идентификации неисправных состояний. Определяется биективная функция  $f: E^1(s_1) \rightarrow \Omega^{np}(s_1)$  и обратная ей  $f^{-1}: \Omega^{np}(s_1) \rightarrow E^1(s_1)$ . Результатом вычисления  $f^{-1}(\Omega_{\tau_1}^{np}(s_1))$  есть множество событий, на основе которых происходит идентификация состояния  $\Omega_{\tau_1}^{np}(s_1) = f(E^1(s_1))$ .

6. Техническое состояние службы  $s_1$  в момент времени  $t_p$  равно:

–  $\Omega^p(s_1)$ , если служба работоспособна или формально, если  $E_p(s_1) \in E^0(s_1)$ ;

–  $f(E_p(s_1))$ , если служба неработоспособна или формально, если  $E_p(s_1) \in E^1(s_1)$ .



$b_{11}$  – время односторонней задержки доставки пакета фиксированной длины от узла N1 к узлу N2.

$b_{12}$  – скорость передачи данных между узлами N1 и N2.

$b_{21}$  – процент использования пропускной способности порта коммутатора Sw1, к которому подключен маршрутизатор R1.

$b_{31}$  – скорость появления пакетов с ошибками на интерфейсе I11 маршрутизатора R1.

$b_{32}$  – процент загрузки процессора маршрутизатора R1.

$b_{33}$  – скорость появления пакетов с ошибками на интерфейсе I12 маршрутизатора R1.

$b_{41}$  – скорость появления пакетов с ошибками на интерфейсе I21 маршрутизатора R2.

$b_{42}$  – процент загрузки процессора маршрутизатора R2.

$b_{43}$  – скорость появления пакетов с ошибками на интерфейсе I22 маршрутизатора R2.

$b_{51}$  – процент использования пропускной способности порта коммутатора Sw2, к которому подключен маршрутизатор R2.

Рис. 1. Схема построения типичного участка IP-сети

Рассмотрим процесс диагностирования службы IP-телефонии на участке IP-сети, схема которого представлена на рис.1. Для доступа к голосовому шлюзу N2 используется канал передачи данных, образованный коммутаторами «Sw1» и «Sw2», маршрутизаторами «R1», «R2» и линиями связи. Указанное оборудование содержит SNMP-агентов, обеспечивающих доступ к текущим значениям SNMP-объектов управления посредством соответствующего протокола. Рабочая станция N1 предназначена для сбора и анализа диагностических данных, поступающих через протокол SNMP. Кроме того, программное обеспечение N1 позволяет измерить характеристики канала передачи данных на участке «N1-Sw1-R1-R2-Sw2-N2» и предоставить текущие значения в виде SNMP-объектов управления.

Процесс диагностирования службы IP-телефонии на участке IP-сети (рис. 1), опишем в виде диагностической модели (1). Основные объекты модели и их описание представлены в таблице 1.

Таблица 1

Диагностическая модель участка IP-сети (рис. 1)

Объект модели	Описание
$S = \{s_1\}, L = 1$	$s_1$ – служба IP-телефонии
$A := \{a_1, a_2, a_3, a_4, a_5\}, I = 5$	$a_1$ – рабочая станция N1, $a_2$ – коммутатор Sw1 $a_3$ – маршрутизатор R1, $a_4$ – маршрутизатор R2 $a_5$ – коммутатор Sw2
$B_1 = \{b_{11}, b_{12}\}, J_1 = 2$	SNMP-объекты для контроля общих характеристик канала передачи данных «N1-Sw1-R1-R2-Sw2-N2»
$B_2 = \{b_{21}\}, J_2 = 1$	Диагностические параметры, соответствующие SNMP-объектам коммутатора Sw1
$B_3 = \{b_{31}, b_{32}, b_{33}\}, J_3 = 3$	Диагностические параметры, соответствующие SNMP-объектам маршрутизатора R1
$B_4 = \{b_{41}, b_{42}, b_{43}\}, J_4 = 3$	Диагностические параметры, соответствующие SNMP-объектам маршрутизатора R2
$B_5 = \{b_{51}\}, J_5 = 1$	Диагностические параметры, соответствующие SNMP-объектам коммутатора Sw2
$N^B = 10$	Общее количество диагностических параметров
$D(b_{11}) = \{1...400\}, D_{111}(b_{11}) = \{1...200\}$ $D_{112}(b_{11}) = \{201...400\}, K_{11} = 2$	Рекомендуемые значения времени односторонней задержки доставки пакета для различных типов каналов передачи данных содержатся в документе ITU-T G.114 “One way transmission time”. Значения в миллисекундах.
$D(b_{12}) = \{1...2000\}, D_{121}(b_{12}) = \{41...2000\}$ $D_{112}(b_{11}) = \{1...40\}, K_{12} = 2$	Рекомендуемые значения скорости передачи данных для различных типов кодеков определены на основе рекомендаций, изложенных в документе ITU-T G.113 “Transmission impairments”. Значения в Кбит/секунду.
$D(b_{21}) = D(b_{32}) = D(b_{42}) = D(b_{51}) = \{1...100\}$ $D_{221}(b_{21}) = D_{321}(b_{32}) = D_{421}(b_{42}) = D_{511}(b_{51}) = \{1...20\}$ $D_{212}(b_{21}) = D_{322}(b_{32}) = D_{422}(b_{42}) = D_{512}(b_{51}) = \{21...40\}$ $D_{213}(b_{21}) = D_{323}(b_{32}) = D_{423}(b_{42}) = D_{513}(b_{51}) = \{41...60\}$ $D_{214}(b_{21}) = D_{324}(b_{32}) = D_{424}(b_{42}) = D_{514}(b_{51}) = \{61...80\}$ $D_{215}(b_{21}) = D_{325}(b_{32}) = D_{425}(b_{42}) = D_{515}(b_{51}) = \{81...100\}$ $D(b_{31}) = D(b_{33}) = D(b_{41}) = D(b_{43}) = \{1...500\}$ $D_{311}(b_{31}) = D_{331}(b_{33}) = D_{411}(b_{41}) = D_{431}(b_{43}) = \{1...100\}$ $D_{312}(b_{31}) = D_{332}(b_{33}) = D_{412}(b_{41}) = D_{432}(b_{43}) = \{101...200\}$ $D_{313}(b_{31}) = D_{333}(b_{33}) = D_{413}(b_{41}) = D_{433}(b_{43}) = \{201...300\}$ $D_{314}(b_{31}) = D_{334}(b_{33}) = D_{414}(b_{41}) = D_{434}(b_{43}) = \{301...400\}$ $D_{315}(b_{31}) = D_{335}(b_{33}) = D_{415}(b_{41}) = D_{435}(b_{43}) = \{401...500\}$ $K_{21} = K_{31} = K_{32} = K_{33} = K_{41} = K_{42} = K_{43} = K_{51} = 5$	Относительно SNMP-объектов, представленных диагностическими параметрами $b_{21}, b_{31}, b_{32}, b_{33}, b_{41}, b_{42}, b_{43}, b_{51}$ , отсутствует информация о том, каким образом их значения распределены между работоспособным и неработоспособным состояниями службы $s_1$ . С целью выявления указанного распределения, множество значений параметров равномерно разбивается на подмножества для проведения дальнейшего исследования.
$V(s_1) = \{b_{11}, b_{12}\}$	Согласно вышеизложенным требованиям, из всех доступных для контроля диагностических параметров в состав множества $V(s_1)$ могут входить только $b_{11}$ и $b_{12}$ , поскольку для остальных восьми неизвестны значения, соответствующие работоспособному и неработоспособному состоянию службы $s_1$ .
$E = \{e_{111}, e_{112}, e_{121}, e_{122}, e_{211}, e_{212}, e_{213}, e_{214}, e_{215}, e_{311}, e_{312}, e_{313}, e_{314}, e_{315}, e_{321}, e_{322}, e_{323}, e_{324}, e_{325}, e_{331}, e_{332}, e_{333}, e_{334}, e_{335}, e_{411}, e_{412}, e_{413}, e_{414}, e_{415}, e_{421}, e_{422}, e_{423}, e_{424}, e_{425}, e_{431}, e_{432}, e_{433}, e_{434}, e_{435}, e_{511}, e_{512}, e_{513}, e_{514}, e_{515}\}$ $N^E = 44$	Множество событий, которые могут использоваться для идентификации состояния корпоративной IP-сети.
$E(s_1) = \{e_{111}, e_{112}, e_{121}, e_{122}\}$	События, которые могут использоваться для описания состояния службы $s_1$ .
$N^\alpha = 1562500$	Количество состояний IP-сети (рис.1), которые можно описать с помощью событий из множества $E$ .
$E_p = \{e_{11k_p}, e_{12k_p}, e_{31k_p}, e_{32k_p}, e_{42k_p}, e_{43k_p}, e_{51k_p}\}$ $\Psi_p = (E_p, p)$	$\Psi_p$ - запись БДДИ, которая описывает состояние IP-сети (рис.1) в момент времени $t_p \in T$ .

$E_p(s_1) = \{e_{11k_{p_1}}, e_{12k_{p_2}}\}$	Описание состояния службы $s_1$ в момент времени $t_p \in T$ .
$E^0(s_1) = \{e_{111}, e_{121}\}$	Вариант формирования $E_p(s_1)$ , соответствующий работоспособному $\Omega^p(s_1)$ состоянию службы $s_1$ .
$E^1(s_1) = \{\{e_{111}, e_{122}\}, \{e_{112}, e_{121}\}, \{e_{112}, e_{122}\}\}$	Варианты формирования $E_p(s_1)$ , соответствующие неработоспособным состояниям службы $s_1$ .
$f(\{e_{111}, e_{122}\}) \rightarrow \Omega_1^{np}(s_1), f(\{e_{112}, e_{121}\}) \rightarrow \Omega_2^{np}(s_1)$ $f(\{e_{112}, e_{122}\}) \rightarrow \Omega_2^{np}(s_1)$	$f: E^1(s_1) \rightarrow \Omega^{np}(s_1)$ – функция для идентификации неисправных состояний службы $s_1$ .

Допустим, что в момент времени  $t_1 < t_p < t_p$  часть компьютеров, подключенных к коммутатору Sw2, была заражена вирусом, который начал генерировать избыточный трафик, проходящий через канал «Sw1-R1-R2-Sw2».

Функционирование вируса стало причиной изменений следующих характеристик работы сетевого оборудования:

- увеличение количества IP-пакетов, проходящих через порт коммутатора Sw1, к которому подключен маршрутизатор R1;
- увеличение процессорного времени, необходимо для обработки маршрутизаторами R1 и R2 поступающих на них пакетов;
- увеличение количества IP-пакетов, проходящих через порт коммутатора Sw2, к которому подключен маршрутизатор R2.

Также изменились и перестали соответствовать требованиям службы  $s_1$  значения общих характеристик канала передачи данных:

- увеличилось время односторонней задержки доставки пакета фиксированной длины от узла N1 к узлу N2;
- уменьшилась скорость передачи данных между узлами N1 и N2.

Симптомами проявления функционирования вируса являются описанные выше изменения значений параметров  $b_{11}, b_{12}, b_{21}, b_{32}, b_{42}, b_{51}$ , однако в процессе определения состояния службы  $s_1$  используются только параметры  $b_{11}, b_{12}$ , которые являются ОДП и выражают требования службы не к характеристикам отдельных компонентов, а к общим характеристикам канала передачи данных как системы взаимодействующих компонентов. Вследствие этой особенности применение ОДП при поиске причин неисправности неэффективно, поскольку по значениям  $b_{11}, b_{12}$  мы не можем заключить, какие из характеристик компонентов отклонились от значений работоспособного состояния службы, и, следовательно, не можем провести локализацию неисправности с точностью до характеристики отдельного компонента.

В рассматриваемой ситуации дополнительные данные для выявления причин отклонения параметров  $b_{11}, b_{12}$  от стандартных значений доступны посредством ЧДП  $b_{21}, b_{32}, b_{42}, b_{51}$  компонентов Sw1, R1, R2, Sw2. Однако применение указанных ЧДП невозможно, так как они являются неопределенными параметрами службы  $s_1$  и для каждого из них неизвестны значения, соответствующие ра-

ботоспособному и неработоспособному состоянию службы  $s_1$ .

Для использования неопределенных параметров в процессе поиска причин неисправного состояния службы необходимо разработать метод, который бы посредством анализа БДДИ, содержащей в событийно-ориентированном виде результаты наблюдения за работой корпоративной IP-сети, позволял находить закономерности между фактами принятия значений параметрами из множества  $V(s_1)$  и параметрами из множества  $(V = \bigcup_i^I B_i) / V(s_1)$ .

#### 4. Метод поиска закономерностей в БДДИ корпоративной IP-сети.

Поскольку событие  $e_{ij,k_{ij}}$  представляет собой факт принятия параметром  $b_{ij}$  значения из множества  $D_{ij,k_{ij}}$ , тогда поиск закономерностей между значениями собственных параметров из множества  $V(s_1)$  и значениями неопределенных параметров из множества  $(V = \bigcup_i^I B_i) / V(s_1)$  равносильно поиску закономерностей между возникновением событий из множества  $E_p(s_1)$  и событий из множества  $E_p / E_p(s_1)$ .

Будем считать, что в момент времени  $t_{p-1}$  (до перехода в неработоспособное состояние), служба  $s_1$  находилась в работоспособном состоянии  $\Omega^p(s_1)$ , описанием которого являлись наборы событий  $E_{p-1}(s_1) = \{e_{111}, e_{121}\}$  и  $E_{p-1} / E_{p-1}(s_1) = \{e_{21k_{21}^{p-1}}, e_{31k_{31}^{p-1}}, e_{32k_{32}^{p-1}}, e_{33k_{33}^{p-1}}, e_{41k_{41}^{p-1}}, e_{42k_{42}^{p-1}}, e_{43k_{43}^{p-1}}, e_{51k_{51}^{p-1}}\}$ .

Из этого следует, что неопределенные параметры  $b_{21}, b_{31}, b_{32}, b_{33}, b_{41}, b_{42}, b_{43}, b_{51}$  в момент времени  $t_{p-1}$  приняли значения из множеств  $D_{21k_{21}^{p-1}}, D_{31k_{31}^{p-1}}, D_{32k_{32}^{p-1}}, D_{33k_{33}^{p-1}}, D_{41k_{41}^{p-1}}, D_{42k_{42}^{p-1}}, D_{43k_{43}^{p-1}}, D_{51k_{51}^{p-1}}$ .

Вследствие функционирования вируса в момент времени  $t_p$  служба перешла в неработоспособное состояние  $\Omega_2^{np}(s_1) = f(\{e_{112}, e_{122}\})$ , которому соответствуют наборы событий  $E_p(s_1) = \{e_{112}, e_{122}\}$  и  $E_p / E_p(s_1) = \{e_{21k_{21}^p}, e_{31k_{31}^p}, e_{32k_{32}^p}, e_{33k_{33}^p}, e_{41k_{41}^p}, e_{42k_{42}^p}, e_{43k_{43}^p}, e_{51k_{51}^p}\}$ .

Следовательно, значения неопределенных параметров  $b_{21}, b_{32}, b_{42}, b_{51}$  изменились таким образом, что стали принадлежать множествам  $D_{21k_{21}^{p'}}$ ,  $D_{32k_{32}^{p'}}$ ,  $D_{42k_{42}^{p'}}$ ,  $D_{51k_{51}^{p'}}$ .

Анализируя состав множества  $E_{p'}/E_{p'}(s_1)$  можно выделить две группы неопределенных параметров:

– Независимые неопределенные параметры (ННП), которые изменяют свои значения независимо от состояния службы  $s_1$ . В рассматриваемом примере к ННП относятся параметры  $(b_{31}, b_{33}, b_{41}, b_{43})$ , значения которых в случае пребывания службы  $s_1$  как в работоспособном, так и в неработоспособном состоянии принадлежат одному и тому же множеству значений.

– Зависимые неопределенные параметры (ЗНП), изменение значений которых в совокупности или по

отдельности является индикатором смены состояния службы. В рассматриваемом примере к группе ЗНП относятся параметры  $(b_{21}, b_{32}, b_{42}, b_{51})$ , значения которых при переходе службы в неработоспособное состояние изменяются и перестают соответствовать значениям, характерным для ее работоспособного состояния.

Исходя из определения ННП, особенности функционирования компонентов, отраженные в значениях ННП, не могут быть причиной перехода службы в неработоспособное состояние. Следовательно, учет их значений при поиске причин неработоспособного состояния службы является избыточной процедурой, что позволяет нам исключить группу ННП из дальнейшего рассмотрения и принимать во внимание только значения ЗНП.

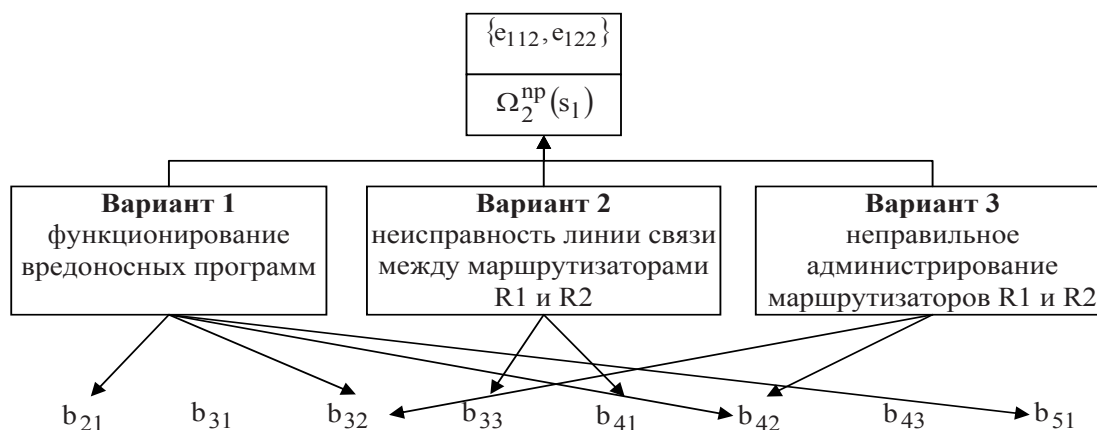


Рис. 2. Схема соответствия ЗДП различным вариантам причин возникновения неработоспособного состояния  $\Omega_2^{np}(s_1)$  службы  $s_1$ .

Некоторому неработоспособному состоянию службы может соответствовать несколько наборов ЗНП. Следует заметить, что принадлежность параметра к

ЗНП или ННП зависит только от причин, которые вызвали неработоспособное состояние службы, и позволяет классифицировать параметры только относительно

Таблица 2

Описание причин возникновения неработоспособного состояния  $\Omega_2^{np}(s_1)$  службы  $s_1$ .

№ варианта	ЗНП	ННП	Описание
1	$b_{21}, b_{32}, b_{42}, b_{51}$	$b_{31}, b_{33}, b_{41}, b_{43}$	Данный вариант рассматривается в качестве примера, его детальное описание представлено ранее в статье.
2	$b_{33}, b_{41}$	$b_{21}, b_{31}, b_{32}, b_{42}, b_{43}, b_{51}$	Канал передачи данных между маршрутизаторами R1 и R2 построен с использованием xDSL модемов, которые работают в однопарном режиме на двух медных линиях связи. Повреждение одной из линий стало причиной увеличения количества фреймов, переданных/принятых с ошибкой на канальном уровне. Необходимость повторной передачи повлияла как на характеристики канала «R1-R2», так и канала «Sw1-R1-R2-Sw2».
3	$b_{32}, b_{42}$	$b_{31}, b_{32}, b_{33}, b_{41}, b_{43}, b_{51}$	Маршрутизаторы R1 и R2 представляют собой устройства Cisco 3800 series. В результате изменения конфигурации был включен режим протоколирования IP-трафика. Выполнение данной задачи чрезвычайно требовательно к ресурсам процессора, вследствие чего процент загрузки процессора поднялся до 95% ( $b_{21}$ ). Даже при нормальной интенсивности трафика это привело к появлению задержек и снижению скорости передачи на всем участке канала «Sw1-R1-R2-Sw2».

заданного неисправного состояния. Данный факт проиллюстрирован на рис. 2 в виде нескольких вариантов причин возникновения неработоспособного состояния  $\Omega_2^{np}(s_1)$ .

Комментарии к каждому из вариантов приведены в таблице 2.

Совокупность наборов событий, которые отражают состояния ЗДП для некоторого неработоспособного состояния, представим в виде множества

$$X_{1\tau_1} = \{x_{1\tau_1,1}, x_{1\tau_1,2}, \dots, x_{1\tau_1, g_{1\tau_1}}, \dots, x_{1\tau_1, G_{1\tau_1}}\}, g_{1\tau_1} = \overline{1, G_{1\tau_1}},$$

где  $G_{1\tau_1}$  – общее количество наборов,  $x_{1\tau_1, g_{1\tau_1}}$  – набор событий с порядковым номером  $g_{1\tau_1}$ , который соответствует неработоспособному состоянию  $\Omega_{\tau_1}^{np}(s_1)$  службы  $s_1$ .

В случае возникновения одной из трех описанных в таблице 2 ситуаций, неработоспособному состоянию  $\Omega_2^{np}(s_1) = f(\{e_{112}, e_{122}\})$  соответствуют следующие наборы событий:

1.  $x_{111} = \{e_{21k_{11}, k_{11} \neq k_{11}^{p-1}}, e_{32k_{32}, k_{32} \neq k_{32}^{p-1}}, e_{42k_{42}, k_{42} \neq k_{42}^{p-1}}, e_{51k_{51}, k_{51} \neq k_{51}^{p-1}}\};$
2.  $x_{112} = \{e_{33k_{33}, k_{33} \neq k_{33}^{p-1}}, e_{41k_{41}, k_{41} \neq k_{41}^{p-1}}\};$
3.  $x_{113} = \{e_{21k_{21}, k_{21} \neq k_{21}^{p-1}}, e_{42k_{42}, k_{42} \neq k_{42}^{p-1}}\}.$

Искомую закономерность между возникновением событий из  $E_p(s_1)$  и событий из  $E_p/E_p(s_1)$  обозначим в виде ассоциативного правила  $\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}$ .

*Определение 6.*

Набор событий  $x_{1\tau_1, g_{1\tau_1}}$  имеет поддержку  $\sup(x_{1\tau_1, g_{1\tau_1}})$ , если  $(\sup(x_{1\tau_1, g_{1\tau_1}}) * P)$  записей БДДИ корпоративной IP-сети содержат  $x_{1\tau_1, g_{1\tau_1}}$ .

*Определение 7.*

Ассоциативное правило  $\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}$  имеет поддержку  $\sup(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}})$ , если  $(\sup(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}) * P)$  записей БДДИ содержат множество событий  $x_{1\tau_1, g_{1\tau_1}} \cup f^{-1}(\Omega_{\tau_1}^{np}(s_1))$ .

*Определение 8.*

Ассоциативное правило  $\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}$  справедливо с достоверностью  $\text{conf}(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}})$ , если  $\text{conf}(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}) * \sup(f^{-1}(\Omega_{\tau_1}^{np}(s_1))) * P$  записей, содержащих события  $f^{-1}(\Omega_{\tau_1}^{np}(s_1))$ , также содержат множество событий  $x_{1\tau_1, g_{1\tau_1}}$ ,

$$\text{conf}(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}) = \sup(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}) / \sup(f^{-1}(\Omega_{\tau_1}^{np}(s_1))).$$

В общем случае процесс поиска ассоциативных правил состоит из трех основных этапов:

1. Поиск в исходном наборе данных часто встречающихся наборов элементов (ЧВНЭ), поддержка которых больше или равна заданному значению.

2. Генерация ассоциативных правил на основе найденных на предыдущем этапе ЧВНЭ. Если  $\{\alpha, \beta, \chi, \delta\}$  – ЧВНЭ элементов, то на его основе можно построить правила  $X \Rightarrow Y$ , такие, что  $X \cup Y = \{\alpha, \beta, \chi, \delta\}$ . Поддержка правила  $X \Rightarrow Y$  будет равна поддержке ЧВНЭ  $\{\alpha, \beta, \chi, \delta\}$ . Достоверность сгенерированного правила равна  $\text{conf}(X \Rightarrow Y) = \sup(X \Rightarrow Y) / \sup(X)$ . Правило добавляется к результирующему набору, при условии, что его достоверность больше заданной.

3. Усечение списка найденных ассоциативных правил. Полученный результирующий набор правил анализируется человеком-экспертом, который удаляет правила, которые, по его мнению, не предоставляют достаточной практической ценности.

Выше описанные этапы позволяют решить классическую задачу поиска ассоциативных правил, которая состоит в поиске всех правил, отвечающих заданным пороговым значениям поддержки и достоверности. В нашем же случае необходимо выявить правила вида  $\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}$ , левая часть которых изначально известна, и задача сводится к поиску всех возможных вариантов правой части, при которых достоверность всего правила будет удовлетворять заданному порогу.

Следует учитывать тот факт, что поддержка всего правила  $\sup(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}})$  не должна выступать в роли ограничения, поскольку, задав ее пороговое значение, мы можем исключить из рассмотрения события, которые объясняют причины неисправного состояния службы. Связано это с тем, что более 90% процентов времени [8] служба находится в работоспособном состоянии. Следовательно, 90% данных, полученных в процессе мониторинга функционирования службы корпоративной IP-сети, содержат значения параметров, которые соответствуют работоспособному  $\Omega^p(s_1)$  состоянию службы  $s_1$  и всего лишь 10% – значения, соответствующие множеству  $\Omega^{np}(s_1)$  неработоспособных состояний службы  $s_1$ . Таким образом, задавая в качестве порогового достаточно низкое значение, равное 0.1, мы заведомо можем отсеять все события, которые описывают неработоспособные состояния из  $\Omega^{np}(s_1)$ .

На практике для решения задачи поиска ассоциативных правил в БДДИ корпоративной IP-сети важна достоверность правила  $\text{conf}(\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}})$ , которая показывает, какова вероятность появления множества событий  $x_{1\tau_1, g_{1\tau_1}}$  при возникновении неработоспособного состояния  $\Omega_{\tau_1}^{np}(s_1)$ .

Исходя из вышеизложенного, процесс поиска ассоциативных правил вида  $\Omega_{\tau_1}^{np}(s_1) \Rightarrow x_{1\tau_1, g_{1\tau_1}}$  в БДДИ корпоративной IP-сети может быть описан ниже перечисленными этапами:

1. Формирование для каждого неработоспособного состояния службы  $\Omega_{\tau_1}^{np}(s_1)$  набора  $\Psi(\Omega_{\tau_1}^{np}(s_1))$  записей БДДИ, которые содержат события  $f^{-1}(\Omega_{\tau_1}^{np}(s_1))$

2. Поиск в наборе  $\Psi(\Omega_{\tau_1}^{np}(s_1))$  множеств событий  $x_{1\tau_1, g_{1\tau_1}}$ , которые удовлетворяют следующему требованию:

$$\sup(\Omega_{\tau_1}^{np}(s_1) \cup x_{1\tau_1, g_{1\tau_1}}) \geq \text{conf}^0 * \sup(f^{-1}(\Omega_{\tau_1}^{np}(s_1))), \quad (2)$$

где  $\text{conf}^0$  - заданное пороговое значение достоверности для искомым ассоциативных правил.

Правая часть неравенства (2) представляет собой константу, обозначим ее как  $\sigma = \text{conf}^0 * \sup(f^{-1}(\Omega_{\tau_i}^{\text{np}}(s_1)))$ , тогда (2) примет вид:

$$\sup(\Omega_{\tau_i}^{\text{np}}(s_1) \cup x_{1_{\tau_i; \beta_{\tau_i}}}) \geq \sigma, \tag{3}$$

Поскольку мы работаем с набором  $\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))$ , где каждая запись заведомо содержит события  $f^{-1}(\Omega_{\tau_i}^{\text{np}}(s_1))$ , тогда неравенство (3) можно записать в форме:

$$\sup_{\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))} (x_{1_{\tau_i; \beta_{\tau_i}}}) \geq \sigma, \tag{4}$$

где  $\sup_{\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))} (x_{1_{\tau_i; \beta_{\tau_i}}})$  - поддержка множества событий  $x_{1_{\tau_i; \beta_{\tau_i}}}$  в наборе записей  $\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))$ . Следовательно, поиск ассоциативных правил  $\Omega_{\tau_i}^{\text{np}}(s_1) \Rightarrow x_{1_{\tau_i; \beta_{\tau_i}}}$ , достоверность которых выше или равна пороговому значению  $\text{conf}^0$ , сводится к поиску ЧВНЭ с поддержкой не менее  $\sigma$  в наборе записей  $\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))$  БДДИ.

3. Удаление человеком-экспертом из результирующего списка ассоциативных правил, которые не представляют интереса при поиске причин неисправного состояния.

На сегодняшний день исследователи в области Data Mining [9] выделяют три типа методов поиска ЧВНЭ элементов в транзакционных наборах данных [10,11]:

1. всех ЧВНЭ;
2. максимальных ЧВНЭ;
3. замкнутых ЧВНЭ.

Пусть в 50% случаев служба  $s_1$  находится в работоспособном состоянии  $\Omega_2^{\text{np}}(s_1)$  по причинам, которые соответствуют варианту №2 (таблица 2), в 25% по причинам, которые соответствуют варианту №1 или №3 (таблица 2). Пусть для трех рассматриваемых вариантов состояние ЗДП описывается множествами событий  $\{e_{212}, e_{322}, e_{422}, e_{512}\}$ ,  $\{e_{332}, e_{412}\}$ ,  $\{e_{212}, e_{422}\}$ .

Примем в качестве порогового значения достоверности искомым ассоциативных зависимостей значение, равное 0,15. Для заданного порогового значения в наборе записей  $\Psi(\Omega_2^{\text{np}}(s_1))$  проведем поиск часто встречающихся множеств с помощью методов трех вышеуказанных типов. Результаты поиска представлены в таблице 3.

**Таблица 3**

**Результаты работы методов поиска ЧВНЭ**

Тип метода	Состав результирующего множества $X_{12}$	Поддержка
1	$\{e_{212}\}, \{e_{322}\}, \{e_{422}\}, \{e_{512}\}, \{e_{212}, e_{322}\}, \{e_{212}, e_{422}\}, \{e_{212}, e_{512}\}, \{e_{322}, e_{422}\}, \{e_{322}, e_{512}\}, \{e_{422}, e_{512}\}, \{e_{212}, e_{322}, e_{422}\}, \{e_{212}, e_{322}, e_{512}\}, \{e_{212}, e_{422}, e_{512}\}, \{e_{322}, e_{422}, e_{512}\}, \{e_{212}, e_{322}, e_{422}, e_{512}\}$	0,25
	$\{e_{212}\}, \{e_{422}\}, \{e_{212}, e_{422}\}, \{e_{322}\}, \{e_{412}\}, \{e_{332}, e_{412}\}$	0,5
2	$\{e_{212}, e_{322}, e_{422}, e_{512}\}$	0,25
	$\{e_{332}, e_{412}\}$	0,5
3	$\{e_{212}, e_{322}, e_{422}, e_{512}\}$	0,25
	$\{e_{332}, e_{412}\}, \{e_{212}, e_{422}\}$	0,5

Методы поиска всех ЧВНЭ находят необходимые множества  $\{e_{212}, e_{322}, e_{422}, e_{512}\}$ ,  $\{e_{332}, e_{412}\}$ ,  $\{e_{212}, e_{422}\}$ , однако результат содержит также избыточные подмножества, которые могут быть получены простым перебором элементов множества  $\{e_{212}, e_{322}, e_{422}, e_{512}\}$ . Метод поиска максимальных ЧВНЭ решает проблему избыточных подмножеств, но при его использовании теряется информация о действительном значении поддержки набора  $\{e_{212}, e_{422}\}$ .

Необходимый результат возвращают методы поиска замкнутых ЧВНЭ, которые ищут максимально возможные множества с уникальным значением поддержки. То есть в случае их использования в результирующем списке для любого множества не существует надмножества с таким же значением поддержки.

Принимая во внимание выкладки данного раздела, метод поиска закономерностей между значениями собственных параметров из множества  $B(s_1)$  и значениями неопределенных параметров из множества  $(B = \bigcup_i B_i) / B(s_1)$  может быть описан следующим образом:

1. Процесс мониторинга состояния корпоративной IP-сети организуем в соответствии с требованиями модели (1).

2. Используем для идентификации состояния службы  $s_1$  методику, представленную ранее в статье.

3. Для неисправного состояния  $\Omega_{\tau_i}^{\text{np}}(s_1)$  формируем набор  $\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))$  записей, которые содержат события  $f^{-1}(\Omega_{\tau_i}^{\text{np}}(s_1))$ .

4. Задаем пороговое значение  $\text{conf}^0$  достоверности искомым ассоциативных правил.

5. Используем метод поиска замкнутых ЧВНЭ, входными данными для которого являются набор записей  $\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))$  и пороговое значение поддержки

$$\text{sup}^0 = \text{conf}^0 * \frac{|\Psi(\Omega_{\tau_i}^{\text{np}}(s_1))|}{|\Psi|}$$

6. Полученные на этапе 5 множества, используем для формирования множества  $X_{1\tau}$  и ассоциативных правил вида  $\Omega_{\tau_i}^{\text{np}}(s_1) \Rightarrow x_{1_{\tau_i; \beta_{\tau_i}}}$ .

7. Путем проведения экспертной оценки отсекаем результирующий список ассоциативных правил и удаляем те из них, которые не представляют интереса при поиске причин неисправного состояния  $\Omega_{\tau_i}^{\text{np}}(s_1)$ .

8. Этапы 3-7 выполняем для всего множества неисправных состояний  $\Omega^{\text{np}}(s_1)$  службы  $s_1$ .

9. Этапы 2-8 проделываем для всех служб IP-сети.

**5. Выводы**

Научная новизна работы состоит в применении методов DataMinig для поиска закономерностей между значениями диагностических параметров служб корпоративной IP-сети.

Выявленные закономерности в дальнейшем могут быть использованы для получения информации о существующих скрытых зависимостях в работе аппаратных и программных компонентов IP-сети.



Применение метода поиска закономерностей в БДДИ корпоративной IP-сети дает возможность автоматизировать процесс создания и поддержки в актуальном состоянии базы знаний, которая может быть включена в состав системы диагностики или системы поддержки принятия решения для обслуживающего персонала корпоративной IP-сети.

В работе также представлена методика определения состояния службы корпоративной IP-сети и введения классификация диагностических параметров.

В качестве дальнейшего направления исследования рассматривается разработка метода, который бы позволял, используя обнаруженные в результате анализа БДДИ закономерности, искать наборы событий, которые с заданной вероятностью идентифицируют причины неисправностей служб корпоративной IP-сети.

---

#### Литература

1. Thottan, M. Anomaly detection in IP networks [Текст] / M.Thottan, C. Ji // IEE Transaction on signal processing. – 2003. – Vol.21, №8. – P.2191-2204.
2. Klemettinen, M. Rule discovery in telecommunication alarm data [Текст] / M. Klemettinen, H. Mannila, H. Toivonen // Journal of Network and Systems Management. – 1999. – Vol.7(4). – P. 395-423.
3. Klemettinen, M. Interactive exploration of interesting patterns in the Telecommunication network alarm sequence analyzer TASA [Текст] / M. Klemettinen, H. Mannila, H. Toivonen // Information and Software Technology. – 1999. – Vol.41(9). – P.557-567.
4. Ndousse, T. D. Computational intelligence for distributed fault management in networks using fuzzy cognitive maps [Текст] / T. D. Ndousse and T. Okuda // in Proc.IEEE ICC. – Dallas. – TX, Jun. 1996. – P.1558–1562.
5. Кучер, А.В. Динамический анализ и диагностика состояния IP-сети [Электронный ресурс] : дис. ... канд. техн. наук / А.В.Кучер. – М.: РГБ, 2007 (Из фондов Российской Государственной библиотеки). – Режим доступа: [www/ URL: http://diss.rsl.ru/diss/05/0616/050616043.pdf](http://diss.rsl.ru/diss/05/0616/050616043.pdf).
6. Сашин, С.В. Диагностика сети абонентского доступа с использованием информационных технологий [Электронный ресурс] : дис. ... канд. техн. наук / С.В.Сашин. – М.: РГБ, 2005 (Из фондов Российской Государственной библиотеки). – Режим доступа: [www/ URL: http://diss.rsl.ru/diss/05/0464/050464041.pdf](http://diss.rsl.ru/diss/05/0464/050464041.pdf)
7. ГОСТ 20911-89 Техническая диагностика Термины и определения [Текст]. – Введ. 1989-09-26.
8. Олифер, В.Г. Компьютерные сети. Принципы, технологии, протоколы [Текст] : Учебник для вузов. 3-е изд. / В. Г. Олифер, Н. А. Олифер. – СПб.: Питер, 2006. – 958с.
9. Fayyad U. From data mining to knowledge discovery in databases [Текст] / U.Fayyad, G.Piatetsky-shapiro, P.Smyth // AI Magazine. – 1996. – Vol.17. – P.37-54.
10. Goethals, Bart. Advances in Frequent Itemset Mining Implementations: Report on FIMI'03 [Электронный ресурс] / Bart Goethals, M.J. Zaki. – CiteSeer. Scientific Literature Digital Library and Search Engine. – Режим доступа: [www/ URL: http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.3.136&rep=rep1&type=pdf](http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.3.136&rep=rep1&type=pdf).
11. Ceglar, A. Association mining [Электронный ресурс] / John F. Roddick, A. Ceglar // ACM Computing Surveys (CSUR) – 2006. – Vol. 38(2), – Issue 2. – Article No. 5. – Режим доступа: [www/ http://doi.acm.org/10.1145/1132956.1132958](http://doi.acm.org/10.1145/1132956.1132958) – 31.03.2009. – Загл. с экрана.