СЕТЕВАЯ СИСТЕМА ОБНАРУЖЕНИЯ АТАК НА ОСНОВЕ ГИБРИДИЗАЦИИ МЕТОДОВ ВЫЧИСЛИТЕЛЬНОГО ИНТЕЛЛЕКТА

Выступающий: А.А. Браницкий
Руководители: д.т.н., проф. А.В. Тимофеев,
д.т.н., проф. И.В. Котенко

Федеральное государственное бюджетное учреждение науки Санкт-Петербургский институт информатики и автоматизации Российской академии наук

Санкт-Петербург, 2017

Актуальность темы исследования

- Совершенствование информационных технологий и рост компьютерных сетей порождают сетевой трафик, обладающий свойствами динамичности и несезонной изменчивости
- Большинство систем обнаружения атак (СОА) не способны выявлять модификации сетевых атак
- Применение адаптивных подходов позволяет избавиться от постоянного обновления базы сигнатур атак в СОА
- „Слепое“ использование адаптивных подходов для обнаружения широкого класса атак приводит к увеличению числа ложных срабатываний
- Слабая ориентация существующих СОА на классификацию сетевых атак приводит к формированию неоднозначных действий, направленных на предотвращение сетевых угроз
- Требуется разработать подход, позволяющий совместить основные преимущества сигнатурных и адаптивных механизмов, для решения задачи обнаружения аномальных сетевых соединений

Цель и задачи исследования

Цель: повышение эффективности функционирования СОА при помощи подхода „гибридизация методов вычислительного интеллекта (ВИ)“.

Задачи:

1. Анализ сигнатурных и эвристических методов для обнаружения сетевых атак
2. Критический анализ открытых программных решений для обнаружения и предотвращения сетевых атак
3. Разработка программных инструментов для тестирования сетевых СОА
4. Экспериментальная проверка способности сетевых СОА к обнаружению сетевых атак со скрытием и со вставкой
5. Разработка модели, алгоритма и методики обнаружения и классификации аномальных сетевых соединений на основе методов ВИ
6. Разработка алгоритмов параллельного поиска шаблонных подстрок для сигнатурных правил СОА.
7. Разработка архитектуры СОА на основе комбинированного подхода, включающего сигнатурный анализ и методы ВИ
8. Разработка программного стенда для генерации сетевых атак
9. Выделение характерных признаков нормальных и аномальных сетевых соединений и создание на их основе набора данных, пригодного для обучения и тестирования классификационных моделей
10. Экспериментальная оценка классификационных моделей с учетом предложенных критериев качества распознавания сетевых атак

Подходы к обнаружению сетевых атак

Авторы (год)	**Система**	**Математический аппарат**
Ilgun K., Kemmerer R. A., Porras P. A. (1995)	USTAT	Конечные автоматы
Kumar S., Spafford E. H. (1995)	IDIOT	Раскрашенные сети Петри
Bombonato F. (2003)	Beholder IDS	Нейронные сети
Paxson V. (1995)	Bro	Язык описания сценариев
Roesch M. (1998)	Snort	Сопоставление с образцом
Lunt T. F., Tamaru A., Gillham F., [et al.] (1992)	IDES	Экспертно-логический вывод
Barbara D., Wu N., Jajodia S. (2001)	ADAM	Наивный байесовский классификатор
Hofmeyr S. A., Forrest S. (2000)	LISYS	Иммунные системы

Постановка задачи исследования

Исходные данные:

- Множество классов сетевых соединений $\mathcal{C} = \{C_0, \ldots, C_m\}$
  - ✓ Класс нормальных сетевых соединений C_0
  - ✓ Классы аномальных сетевых соединений $C_1, \ldots, C_m$
- Набор маркированных векторов признаков сетевых соединений $\left(\Upsilon_{\mathcal{X}_{\mathcal{C}}^{(LS)}} = \{(\boldsymbol{x_i}, \bar{c}_i)\}_{i=1}^{M}\right) \bigcup \left(\Upsilon_{\mathcal{X}_{\mathcal{C}}^{(TS)}} = \{(\boldsymbol{z_i}, \bar{c}_i)\}_{i=1}^{M^*}\right)$
- Множество конфигурационных параметров дерева классификаторов и отдельных классификаторов

Ограничения и допущения:

- Между узловыми сенсорами и коллектором СОА организован высокоскоростной безопасный канал передачи данных
- Среда функционирования СОА является безопасной с точки зрения вызова системных функций ОС
- Права суперпользователя для запуска компонентов СОА предоставлены

Постановка задачи исследования

Требуется разработать:

1. модель вычислительной иммунной системы на базе эволюционного подхода, которая является независимой от структуры внутреннего представления иммунных детекторов и учитывает свойства динамического непостоянства сетевого трафика
2. алгоритм генетико-конкурентного обучения сети Кохонена, который направлен на снижение числа эпох обучения за счет использования различных стратегий генетической оптимизации весов мертвых нейронов
3. методику иерархической гибридизации бинарных классификаторов, которая, в отличие от остальных, предоставляет возможность объединения разнородных решателей без строгой привязки к агрегирующей их выходы композиции
4. архитектуру распределенной СОА, построенной на основе комбинирования сигнатурного анализа и методов ВИ

Результаты, выносимые на защиту

Модель вычислительной иммунной системы на базе эволюционного подхода

Алгоритм генетико-конкурентного обучения сети Кохонена

Методика иерархической гибридизации бинарных классификаторов для выявления аномальных сетевых соединений

Архитектура распределенной СОА, построенной на основе комбинирования сигнатурного анализа и методов ВИ

Результаты

Результат 1

Модель вычислительной иммунной системы на базе эволюционного подхода

Постановка задачи

Исходные данные:

- $\mathcal{C} = \{C_0, \ldots, C_m\}$ — множество классов сетевых соединений
- $\Upsilon_{\mathcal{X}_{\mathcal{C}}^{(LS)}} = \{(\boldsymbol{x_i}, \bar{c}_i)\}_{i=1}^{M}$ — маркированная обучающая выборка
- $\Upsilon_{\mathcal{X}_{\mathcal{C}}^{(TS)}} = \{(\boldsymbol{z_i}, \bar{c}_i)\}_{i=1}^{M^*}$ — маркированная контрольная выборка

Ограничения и допущения:

- Модель должна динамически переобучаться на новых данных

Требуется: разработать модель $AISEA$ и алгоритм классификации G сетевых соединений на основе этой модели:

$$\frac{\#\left\{\boldsymbol{z_i} \,\middle|\, \boldsymbol{z_i} \in \mathcal{X}_{\mathcal{C}}^{(TS)} \wedge \{\bar{c}_i\} = G\left(\boldsymbol{z_i}\right)\right\}_{i=1}^{M^*}}{\#\left\{\boldsymbol{z_i} \,\middle|\, \boldsymbol{z_i} \in \mathcal{X}_{\mathcal{C}}^{(TS)}\right\}_{i=1}^{M^*}} \longrightarrow \max_{G}$$

$$\frac{\#\left\{\boldsymbol{z_i} \,\middle|\, \boldsymbol{z_i} \in \mathcal{X}_{\mathcal{C}}^{(TS)} \wedge \{\bar{c}_i\} \in G\left(\boldsymbol{z_i}\right) \wedge \#G\left(\boldsymbol{z_i}\right) \geqslant 2\right\}_{i=1}^{M^*}}{\#\left\{\boldsymbol{z_i} \,\middle|\, \boldsymbol{z_i} \in \mathcal{X}_{\mathcal{C}}^{(TS)}\right\}_{i=1}^{M^*}} \longrightarrow \min_{G}$$

Вычислительная иммунная система

$AISEA = \langle \mathcal{D}_\mathcal{T}, \mathcal{D}_\mathcal{M}, \mathcal{S}_\mathcal{A}, \mathcal{S}_\mathcal{N}, \mathcal{G}, R, \Psi \rangle$ — иммунная система

- $\mathcal{D}_\mathcal{T} \subset \mathcal{D}$ — набор временных иммунных детекторов
- $\mathcal{D}_\mathcal{M} \subset \mathcal{D}$ — набор иммунных детекторов памяти
- $\mathcal{S}_\mathcal{A} \subset \mathcal{S}$ — обучающий набор („чужие“ объекты)
- $\mathcal{S}_\mathcal{N} \subset \mathcal{S}$ — тестирующее множество („свои“ объекты)
- $\mathcal{D} = \mathcal{D}_\mathcal{T} \bigcup \mathcal{D}_\mathcal{M}$ — набор иммунных детекторов
- $\mathcal{G} = \{G_1, \ldots, G_K\}$ — стратегии генетической оптимизации иммунных детекторов
- $R : \mathcal{D} \times 2^{\mathcal{S}_\mathcal{A}} \times 2^{\mathcal{S}_\mathcal{N}} \times \mathcal{G} \to \mathcal{D}$ — правило обучения иммунных детекторов
- $\mathcal{S}$ — набор всевозможных входных объектов
- $\Psi : \mathcal{D} \times \mathcal{S} \to [0, +\infty)$ — функция вычисления аффинности между иммунным детектором $d \in D$ и тестовым объектом $s \in S$

$d = \langle representation, threshold, life\_time, state \rangle$ — иммунный детектор

- $representation \in \{BitString, RealVector, NeuralNetwork, PetriNet, \ldots\}$ — внутреннее представление иммунного детектора d
- $threshold \in [0, +\infty)$ — порог активации иммунного детектора d
- $life\_time \in [0, +\infty]$ — срок жизни иммунного детектора d
- $state \in \{immature, semimature, mature, memory\}$ — текущее состояние иммунного детектора d

Жизненный цикл иммунного детектора

$\mathcal{D}_{\mathcal{M}}$ и $threshold$

- Для обнаружения каждого класса атаки $C \in \mathcal{C}$ выделяется несколько иммунных детекторов, объединяющихся в класс детекторов $\mathcal{D}_C$ ($\bigcup_{C \in \mathcal{C}} \mathcal{D}_C = \mathcal{D}$).
- Каждый из детекторов $d \in \mathcal{D}_C$ использует бутстреп-обучение на разных случайных подвыборках множеств $\mathcal{S}_{\mathcal{A}}$ и $\mathcal{S}_{\mathcal{N}} - \mathcal{S}_{\mathcal{A}}^{(d)}$ и $\mathcal{S}_{\mathcal{N}}^{(d)}$.
- Под q-ой группой детекторов понимается набор детекторов $\mathcal{D}^{(q)}$ ($\bigcup_{q=1}^{m} \mathcal{D}^{(q)} = \mathcal{D}$, m — число классов атак), полностью покрывающих всё множество классов атак.
- Для каждого класса атаки $C \in \mathcal{C}$ определяется ровно один детектор памяти $d_m^{(C)}$ — детектор, который удовлетворяет требованию наибольшей степени приспособленности к распознаванию объектов класса C.

$$\mathcal{D}_{\mathcal{M}} = \bigcup_{C \in \mathcal{C}} \left\{ \operatorname{Arg\,max}_{d \in \mathcal{D}_C} \left(\sum_{s \in \mathcal{S}_{\mathcal{A}}^{(d)} \cap C} \Psi(d, s) / \# \left(\mathcal{S}_{\mathcal{A}}^{(d)} \cap C \right) \right) \right\}$$

$$threshold = h_d^- - \frac{h_d^- - h_d^+}{2} = \frac{h_d^- + h_d^+}{2} = \frac{\min_{s \in \mathcal{S}_{\mathcal{A}}^{(d)}} \Psi(d,s) + \max_{s \in \mathcal{S}_{\mathcal{N}}^{(d)}} \Psi(d,s)}{2}$$

Алгоритм классификации соединений

1. Вычисление для каждого иммунного детектора $d \in \mathcal{D}$ значения его активации $a_d = \Psi(d, s) - threshold$.
2. Мажоритарное голосование внутри каждого класса детекторов $\mathcal{D}_C$. Если $\left(A_C \leftrightharpoons \sum_{d \in \mathcal{D}_C} [a_d \geqslant 0]\right) > \left(B_C \leftrightharpoons \sum_{d \in \mathcal{D}_C} [a_d < 0]\right)$, то s распознается как „чужой“ объект. Если $A_C < B_C$, то s распознается как „свой“ объект. В случае наличия конфликтов, т.е. $A_C = B_C$, s классифицируется как „чужой“ объект, если $a_{d_m^{(C)}} \geqslant 0$, и s классифицируется как „свой“ объект, если $a_{d_m^{(C)}} < 0$, где $d_m^{(C)} \in \mathcal{D}_{\mathcal{M}} \bigcap \mathcal{D}_C$.
3. Формирование множества классов иммунных детекторов $\{\mathcal{D}_{C'}\}_{C' \in \mathcal{C}^*}$, которые распознают входной объект s как „чужой“ объект.
4. Определение класса объекта s. Если $\mathcal{C}^* = \varnothing$, то объект s относится к классу „своих“ объектов. Если $E_{\mathcal{C}^*} \leftrightharpoons \max_{C' \in \mathcal{C}^*} A_{C'}$ достигается в одной единственной точке, то класс объекта s — это $\arg E_{\mathcal{C}^*}$, иначе класс объекта s — это $\arg\max_{C' \in \{\arg E_{\mathcal{C}^*}\}} \sum_{d \in \mathcal{D}_{C'}} a_d \cdot [a_d \geqslant 0]$.

Отличия от других моделей

- Двухуровневый алгоритм обучения с автоматическим вычислением порога активации иммунных детекторов
- Механизм разрешения конфликтных случаев классификации за счет мажоритарного голосования, детекторов памяти и учета суммы взвешенных голосов от активировавшихся на данный стимул детекторов
- Независимость от внутренней структуры представления иммунных детекторов (универсальность модели)

Результаты

Результат 2

Алгоритм генетико-конкурентного обучения сети Кохонена

Постановка задачи

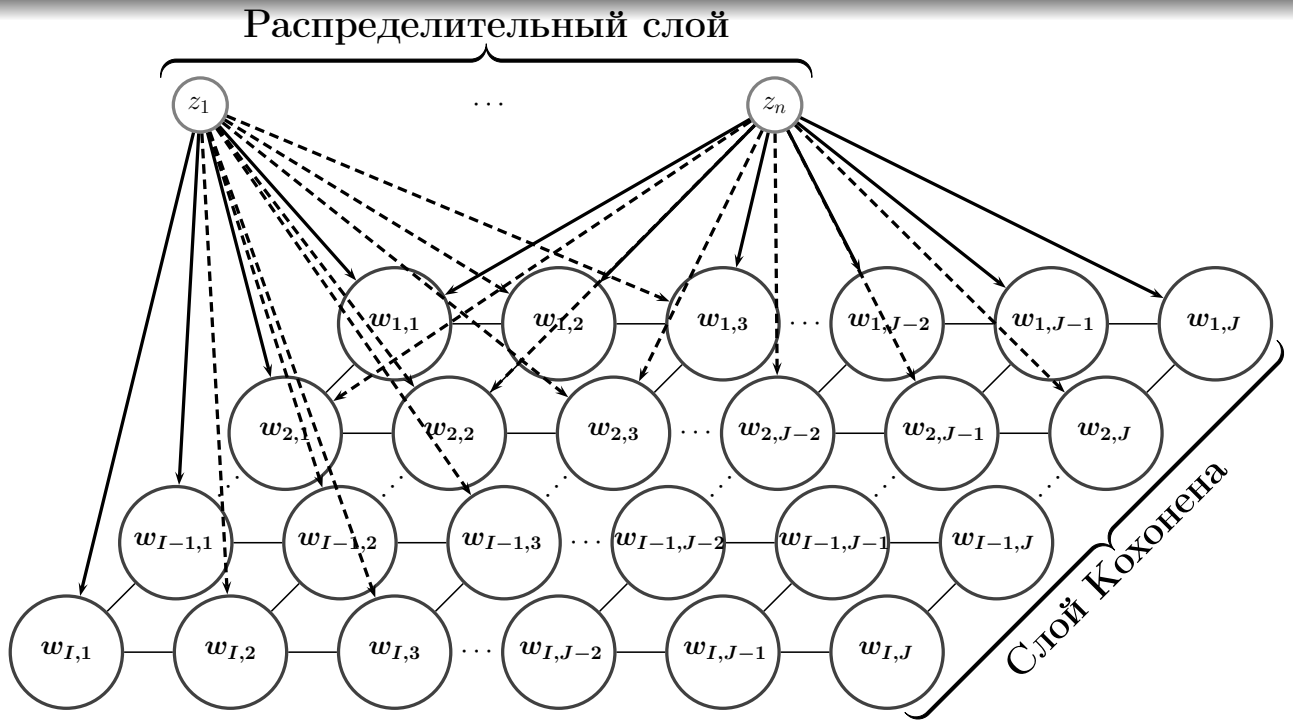

Исходные данные:

- Инициализированные случайными малыми значениями веса сети Кохонена: $\left\{\boldsymbol{w_{ij}}\right\}_{\substack{1\leqslant i\leqslant I\\1\leqslant j\leqslant J}}$
- Набор векторов признаков сетевых соединений класса C: $\left\{\boldsymbol{x_i}\,|\boldsymbol{x_i}\in C\right\}_{i=1}^{M}$
- Набор стратегий генетической оптимизации весов: $\mathcal{G}=\{G_1,G_2,G_3\}$

Ограничения и допущения:

- $T_{modified}\leqslant T_{standard}$

Требуется: разработать алгоритм обучения сети Кохонена:

$$E(\boldsymbol{w_{11}},\ldots,\boldsymbol{w_{IJ}})=\tfrac{1}{2}\cdot\sum_{k=1}^{M}\left(D\left(\boldsymbol{w_{i_k^*j_k^*}},\boldsymbol{x_k}\right)\right)^2\longrightarrow\min_{\boldsymbol{w_{11}},\ldots,\boldsymbol{w_{IJ}}},$$

$$D(\boldsymbol{w},\boldsymbol{x})=\sqrt{(\boldsymbol{w}-\boldsymbol{x})^T\cdot(\boldsymbol{w}-\boldsymbol{x})},(i_k^*,j_k^*)=F_{IJ}(\boldsymbol{x_k})=\arg\min_{\substack{1\leqslant i\leqslant I\\1\leqslant j\leqslant J}}D\left(\boldsymbol{w_{ij}},\boldsymbol{x_k}\right)$$

Стандартный и модифицированный алгоритмы

Стандартный алгоритм

for t **in** $1..T$ **do**
 #Ширина окрестности:
 $\sigma(t) := \sigma_0 \cdot \exp\{-\ln(\sigma_0) \cdot t/T\}$
 (*)
 for $\boldsymbol{x}$ **in** $\{\boldsymbol{x_i} | \boldsymbol{x_i} \in C\}_{i=1}^{M}$ **do**
  #Нейрон-победитель:
  $(i^*, j^*) := F_{IJ}(\boldsymbol{x})$
  #Текущая окрестность:
  $V^* := \{(i,j) \,|\, d^*(i,j) < \sigma^2(t)\}$,
  где $d^*(i,j) = (i-i^*)^2 + (j-j^*)^2$
  for (i,j) **in** V^* **do**
   #Обновление весов:
   $\boldsymbol{w_{ij}} := \boldsymbol{w_{ij}} + \kappa(t) \cdot \varphi(i,j,t) \cdot (\boldsymbol{x} - \boldsymbol{w_{ij}})$,
   где $\kappa(t) = \kappa_0 \cdot e^{-\eta \cdot t}$, $\varphi(i,j,t) = e^{-\frac{d^*(i,j)}{2 \cdot \sigma^2(t)}}$
  od
  (**)
 od
 (***)
od
(****)

Модифицированный алгоритм

(*) #Набор активных нейронов:
$V^+ := \varnothing$
(**) #Расширение набора #активных нейронов:
$V^+ := V^+ \bigcup \{(i^*, j^*)\}$
#Интерактивная настройка:
применение стратегии G' к весам $\boldsymbol{w_{ij}}$, где $(i,j) \in V^\dagger = V^* \setminus \{(i^*, j^*)\}$,
$\Psi_{ijk} = \|\boldsymbol{x} - \boldsymbol{w_{ij}}\|^{-1}$ — ФП
(***) #Пакетная настройка:
применение стратегии G' к весам $\boldsymbol{w_{ij}}$, где $(i,j) \in V^\dagger = V^* \setminus V^+$,
$\Psi_{ij} = \left(\sum_{\boldsymbol{x} \in C} \|\boldsymbol{x} - \boldsymbol{w_{ij}}\| / M\right)^{-1}$ — ФП
(****) #Порог активации нейрона:
$h_{ij}^- := \min\limits_{\boldsymbol{x} \in C} \left\{D^{-1}(\boldsymbol{w_{ij}}, \boldsymbol{x}) \,|\, (i,j) = F_{IJ}(\boldsymbol{x})\right\}$
$h_{ij}^+ := \max\limits_{\boldsymbol{x} \in C_0} \left\{D^{-1}(\boldsymbol{w_{ij}}, \boldsymbol{x}) \,|\, (i,j) = F_{IJ}(\boldsymbol{x})\right\}$
$h_{ij} := (h_{ij}^- + h_{ij}^+)/2$

Генетические операторы

1 Кроссинговер

- ✓ Случайный выбор границы разделения хромосом
- ✓ Перестановка местами участков двух хромосом

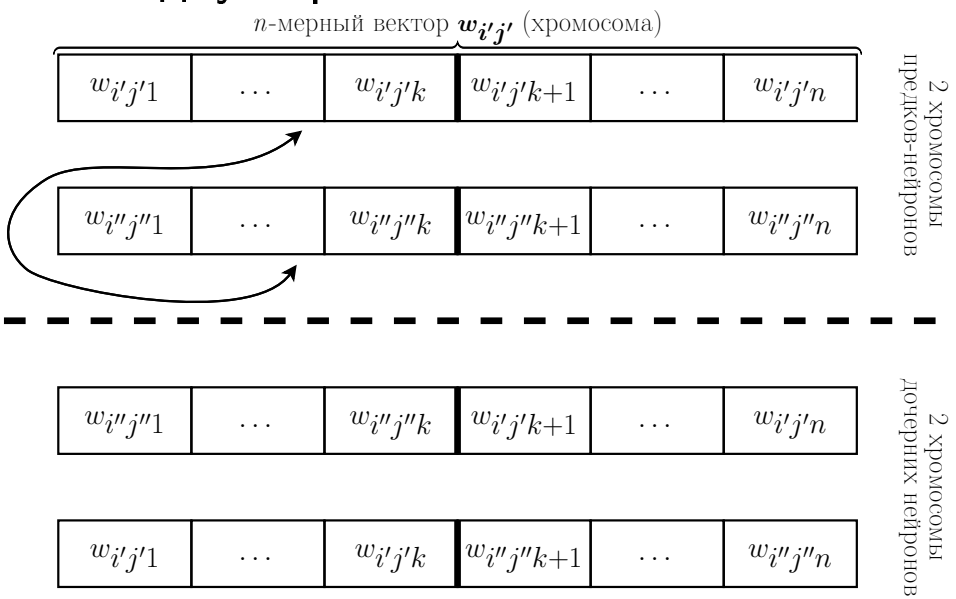

2 Мутация

- ✓ Случайный выбор бит внутри гена
- ✓ Перестановка местами двух бит

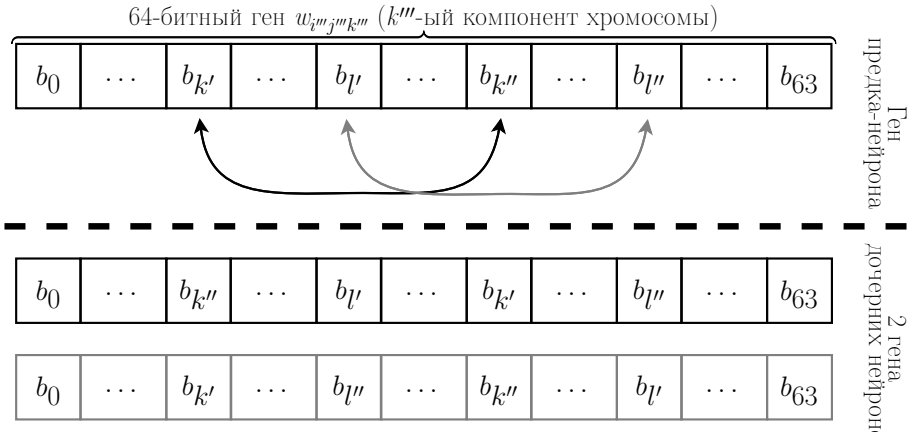

3 Инверсия

- ✓ Случайный выбор бита
- ✓ Инвертирование значения бита

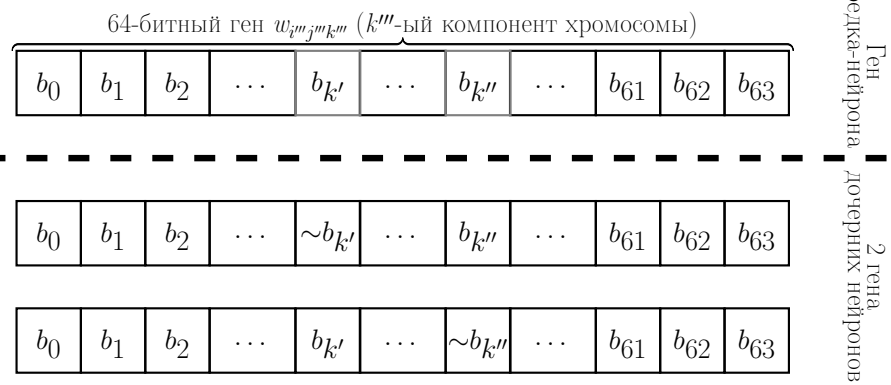

Кроссинговер сохраняет целостность генов, но нарушает порядок их следования. Мутация и инверсия применяются только к части мантиссы 64-битного „вещественного гена“.

Подходы для генерации нейронов

$V := \varnothing$
while $V \neq V^{\dagger}$ **do**
  Выбрать очередной мертвый нейрон $(i', j') \in V^{\dagger}$
  Выбрать случайно один из трех генетических операторов O^*
  if O^* — оператор скрещивания **then**
    Выбрать второй нейрон (i'', j'') на основе одного из трех подходов:
    1. Подход A_1 (случайный):
       $(i'', j'') \in V^* \setminus V \setminus \{(i', j')\}$
    2. Подход A_2 (геометрический):
       $(i'', j'') \in V^* \setminus V \setminus \{(i', j')\} \wedge d^*(i', j') = d^*(i'', j'')$
    3. Подход A_3 (на основе приспособленности):
       $(i'', j'') = \arg\max_{(i,j) \in V^* \setminus V \setminus \{(i', j')\}} \Psi_{ij(k)}$
    Применить оператор O^*к нейронам (i', j') и (i'', j'')
  else
    Применить дважды оператор O^* к нейрону (i', j')
  fi
  $V := V \bigcup \{(i', j')\}$
od

Стратегии генетической оптимизации

1. фиксированный выбор подхода
2. последовательный или случайный перебор подходов
3. выбор, основанный на механизме рулетки

0. $p_{A_i} := \frac{1}{3}$ — начальная вероятность выбора подхода A_i $(i=1,2,3)$
1. Генерация случайного вещественного числа $r \in [0,1]$
2. $[0,1) = r_{A_1} \vee r_{A_2} \vee r_{A_3} = [0, p_{A_1}) \vee [p_{A_1}, p_{A_2}) \vee [p_{A_1} + p_{A_2}, p_{A_3})$
3. Если $r \in r_{A_{i_1^*}}$, то $A_{i_1^*}$ — подход для генерации дочерних нейронов V_2^* и V_3^*
4. $\Psi_{V_l^*} = \frac{1}{\#V_l^*} \cdot \sum_{(i,j) \in V_l^*} \Psi_{ij(k)}$ — усредненное значение ФП $(l=1,2,3)$
5. Если $\Psi_{V_{l^*}^*} > \Psi_{V_1^*}$, то $V_{l^*}^*$ — текущее решение $\left(l^* = \arg\max\limits_{l=2,3} \left\{\Psi_{V_l^*}\right\}\right)$,

$p_{A_{i_1^*}} := p_{A_{i_1^*}} + \Delta'_{A_{i_1^*}}$, $p_{A_{i_2^*}} := p_{A_{i_2^*}} - \Delta'_{A_{i_2^*}}$, $p_{A_{i_3^*}} := 1 - p_{A_{i_1^*}} - p_{A_{i_2^*}}$, где

$\Delta'_{A_{i_1^*}} = \min\left\{\frac{\Psi_{V_{l^*}^*} - \Psi_{V_1^*}}{\Psi_{V_{l^*}^*}}, 1 - p_{A_{i_1^*}}\right\}$, $\Delta'_{A_{i_2^*}} = \min\left\{\frac{1}{2} \cdot \Delta'_{A_{i_1^*}}, p_{A_{i_2^*}}\right\}$;

иначе V_1^* — текущее решение, $p_{A_{i_1^*}} := p_{A_{i_1^*}} - \Delta''_{A_{i_1^*}}$,

$p_{A_{i_2^*}} := p_{A_{i_2^*}} + \Delta''_{A_{i_2^*}}$, $p_{A_{i_3^*}} := 1 - p_{A_{i_1^*}} - p_{A_{i_2^*}}$, где

$\Delta''_{A_{i_1^*}} = \min\left\{\frac{\Psi_{V_1^*} - \Psi_{V_{l^*}^*}}{\Psi_{V_1^*}}, p_{A_{i_1^*}}\right\}$, $\Delta''_{A_{i_2^*}} = \min\left\{\frac{1}{2} \cdot \Delta''_{A_{i_1^*}}, 1 - p_{A_{i_2^*}}\right\}$

Отличия от других алгоритмов

- Генетическая оптимизация позволяет расширить множество активных нейронов сети Кохонена за счет дополнительной настройки мертвых нейронов и их дальнейшего подключения к процессу распознавания сетевых атак
- Каждая стратегия манипулирует выбором подходов; в частности, стратегия „рулетка“ направлена на создание конкурентной борьбы именно между подходами (а не между особями) для генерации дочерних нейронов
- Дополнительная корректировка порога позволяет повысить способность обобщения у сети Кохонена за счет введения постфазы тестирования на нормальных экземплярах

Результаты

Результат 3

Методика иерархической гибридизации бинарных классификаторов для выявления аномальных сетевых соединений

Постановка задачи

Исходные данные:

- $\mathcal{C} = \{C_0, \ldots, C_m\}$ — множество классов сетевых соединений
- $F^{(1)}, \ldots, F^{(P)} : \mathbb{R}^n \to 2^{\{0,\ldots,m\}}$ — коллектив базовых классификаторов
- $\Upsilon_{\mathcal{X}_{\mathcal{C}}^{(LS)}} = \{(\boldsymbol{x_i}, \bar{c}_i)\}_{i=1}^{M}$ — маркированная обучающая выборка
- $\Upsilon_{\mathcal{X}_{\mathcal{C}}^{(TS)}} = \{(\boldsymbol{z_i}, \bar{c}_i)\}_{i=1}^{M^*}$ — маркированная контрольная выборка
- $F : \left(2^{\{0,\ldots,m\}}\right)^P \times \mathbb{R}^n \longrightarrow 2^{\{0,\ldots,m\}}$ — агрегирующая функция
- $G : \mathbb{R}^n \longrightarrow 2^{\{0,\ldots,m\}}$ — агрегирующая композиция
- $\zeta : \mathcal{C} \longrightarrow \{0, \ldots, m\}$ — вспомогательное отображение

Ограничения и допущения:

- Базовые классификаторы — это набор детекторов $F_{jk}^{(i)} : \mathbb{R}^n \to \{0,1\}$
- Настройка базовых классификаторов уже выполнена

Требуется: разработать методику:

$$\Omega(G, \mathcal{X}_{\mathcal{C}}) = \Omega\left(F \circ \left[F^{(1)}, \ldots, F^{(P)}, \underset{1}{\mathbf{id}}\right], \mathcal{X}_{\mathcal{C}}\right) \leqslant \min_{j \in \{1,\ldots,P\}} \Omega\left(F^{(j)}, \mathcal{X}_{\mathcal{C}}\right),$$

$$\Omega(G, \mathcal{X}_{\mathcal{C}}) = \frac{1}{\#\mathcal{X}_{\mathcal{C}}} \cdot \#\left\{\boldsymbol{z} \,|(\exists C \in \mathcal{C}\ \boldsymbol{z} \in C) \wedge G(\boldsymbol{z}) \neq \zeta(C)\right\}_{\boldsymbol{z} \in \mathcal{X}_{\mathcal{C}}}$$

Основные этапы

Этапы 1–2

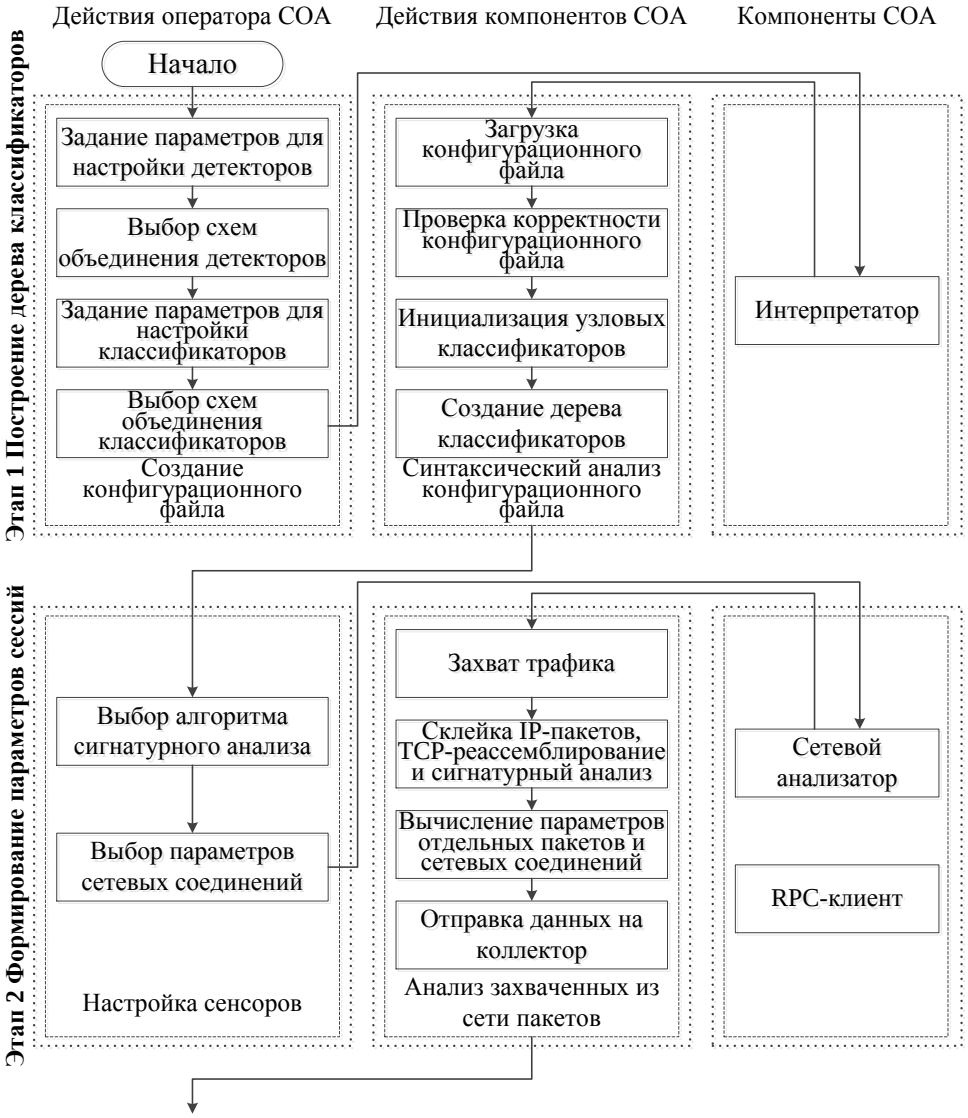

Исследуемые схемы комбинирования детекторов:

1. один-ко-всем (one-vs-all)
2. один-к-одному (one-vs-one)
3. классификационное бинарное дерево (CBT)
4. направленный ациклический граф (DAG)

Исследуемые агрегирующие композиции:

1. метод мажоритарного голосования (ММГ)

$$G^{(MV)}(\boldsymbol{z}) = \left\{ k \left| \sum_{j=1}^{P} \left[k \in F^{(j)}(\boldsymbol{z}) \right] > \frac{1}{2} \cdot \sum_{i=0}^{m} \sum_{j=1}^{P} \left[i \in F^{(j)}(\boldsymbol{z}) \right] \right. \right\}_{k=0}^{m}$$

2. метод взвешенного голосования (МВГ)

$$G^{(WV)}(\boldsymbol{z}) = \left\{ k \left| \sum_{j=1}^{P} \omega_j \cdot \left[k \in F^{(j)}(\boldsymbol{z}) \right] = \max_{i \in \{0,\ldots,m\}} \sum_{j=1}^{P} \omega_j \cdot \left[i \in F^{(j)}(\boldsymbol{z}) \right] \right. \right\}_{k=0}^{m}$$

$$\omega_j = \frac{\#\left\{ \boldsymbol{x_k} \middle| \bar{c}_k \in F^{(j)}(\boldsymbol{x_k}) \right\}_{k=1}^{M}}{\sum_{i=1}^{P} \#\left\{ \boldsymbol{x_k} \middle| \bar{c}_k \in F^{(i)}(\boldsymbol{x_k}) \right\}_{k=1}^{M}}$$

3. метод многоярусной укладки (ММУ)

$$G^{(ST)}(\boldsymbol{z}) = F^{(ST)}\left(F^{(1)}(\boldsymbol{z}), \ldots, F^{(P)}(\boldsymbol{z}), \boldsymbol{z} \right)$$

4. метод Фикса—Ходжеса (МФХ)

$$G^{(FH)}(\boldsymbol{z}) = \bigcup_{l=1}^{P} \left(F^{(l)}(\boldsymbol{z}) \left| \underbrace{\sum_{j=1}^{\widetilde{M}} \left[F^{(l)}(\boldsymbol{x_{i_j}}) = \left\{ \bar{c}_{i_j} \right\} \right]}_{D_{\widetilde{M}}(l)} = \max_{k \in \{1,\ldots,P\}} D_{\widetilde{M}}(k) \right. \right)$$

$$\left\{ i_1, \ldots, i_{\widetilde{M}} \right\} = \arg \min_{\substack{\widetilde{I} \subseteq \{1,\ldots,M\} \\ (\#\widetilde{I} = \widetilde{M})}} \sum_{i \in \widetilde{I}} \rho(\boldsymbol{x_i}, \boldsymbol{z})$$

Дерево классификаторов и сетевые параметры

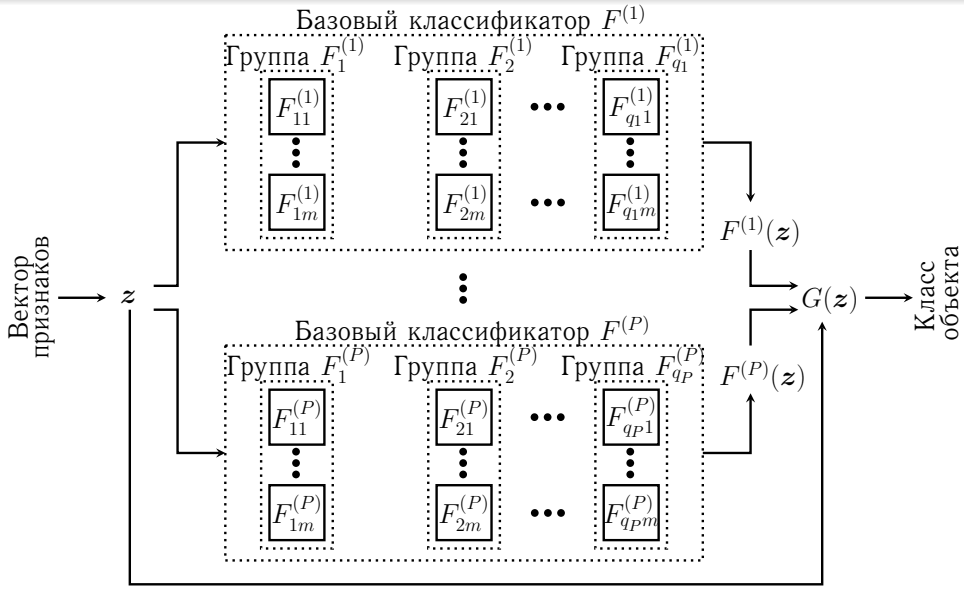

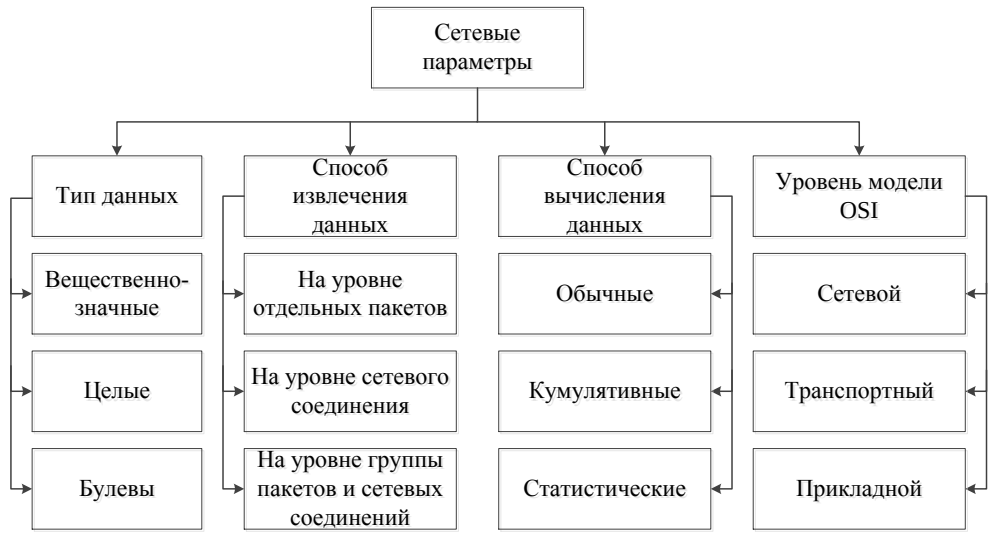

- Каждый классификатор $F^{(i)}$ $(i = 1, \ldots, P)$ содержит q_i групп $F_j^{(i)}$ $(j = 1, \ldots, q_i)$
- Каждая группа объединяет m или больше детекторов $F_{jk}^{(i)}$ $(k = 1, \ldots, m)$
- Группа детекторов $F_j^{(i)}$ обучается на различных случайных бутстреп-подвыборках из $\Upsilon_{\mathcal{X}_{\mathcal{C}}^{(LS)}}$
- Объединение групп $F_j^{(i)}$ в классификатор $F^{(i)}$ осуществляется на основе гибридного правила, представляющего собой смесь голосования большинством и голосования max-wins:

$$F^{(i)}(\boldsymbol{z}) = \left\{ \bar{c} \left| \underbrace{\sum_{j=1}^{q_i} \left[\bar{c} \in F_j^{(i)}(\boldsymbol{z}) \right]}_{\Xi_i(\bar{c})} > \tfrac{1}{2} \cdot q_i \wedge \Xi_i(\bar{c}) = \max_{\bar{c}' \in \{0,\ldots,m\}} \Xi_i(\bar{c}') \right. \right\}_{\bar{c}=0}^{m}$$

Адаптированный метод скользящей средней для вычисления статистических показателей (интенсивности пакетов):

- $\Delta_0^{(L)} = [0, L] = \bigcup_{i=0}^{k-1} \Delta_{\delta \cdot i}^{(L')}$ — наблюдаемый временной интервал $(0 < L' \leqslant L,\ 0 < \delta \leqslant L')$
- $k = 1 + \lfloor \frac{L - L'}{\delta} \rfloor$ — число скользящих интервалов
- ω_i — слепок параметров в течение $\Delta_{\delta \cdot i}^{(L')}$
- $\bar{\omega} = \frac{1}{k} \cdot \sum_{i=0}^{k-1} \omega_i$ — средняя величина (интенсивность)

Этапы 3–5

Показатели эффективности СОА:

1. корректности обнаружения сетевых атак

$$TPR=\frac{TP}{TP+FN}=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\wedge\bar{c}_i\neq 0\wedge 0\notin G(\boldsymbol{z_i})\right\}_{i=1}^{M^*}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\wedge\bar{c}_i\neq 0\right\}_{i=1}^{M^*}}$$

2. ложных срабатываний:

$$FPR=\frac{FP}{FP+TN}=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\wedge\bar{c}_i=0\wedge 0\notin G(\boldsymbol{z_i})\right\}_{i=1}^{M^*}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\wedge\bar{c}_i=0\right\}_{i=1}^{M^*}}$$

3. корректности классификации соединений:

$$CCR=\frac{CC}{TP+FN+FP+TN}=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\wedge\{\bar{c}_i\}=G(\boldsymbol{z_i})\right\}_{i=1}^{M^*}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\right\}_{i=1}^{M^*}}$$

4. некорректной классификации:

$$ICR=\frac{IC}{TP+FN+FP+TN}=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\wedge\bar{c}_i\notin G(\boldsymbol{z_i})\right\}_{i=1}^{M^*}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\mathcal{X}_{\mathcal{C}}^{(TS)}\right\}_{i=1}^{M^*}}$$

5. обобщающей способности при обнаружении:

$$GPR=\frac{\overline{TP^*}}{\overline{TP^*}+\overline{FN^*}}=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(TS)}\setminus\mathcal{X}_{\mathcal{C}}^{(LS)}\wedge\bar{c}_i\neq 0\wedge 0\notin G(\boldsymbol{z_i})\right\}_{i=1}^{\bar{M}^*}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(TS)}\setminus\mathcal{X}_{\mathcal{C}}^{(LS)}\wedge\bar{c}_i\neq 0\right\}_{i=1}^{\bar{M}^*}}$$

6. переобученности при обнаружении:

$$OPR=\overline{TPR}-GPR=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(LS)}\wedge\bar{c}_i\neq 0\wedge 0\notin G(\boldsymbol{z_i})\right\}_{i=1}^{\bar{M}}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(LS)}\wedge\bar{c}_i\neq 0\right\}_{i=1}^{\bar{M}}}-GPR$$

7. обобщающей способности при классификации:

$$GCR=\frac{\overline{CC^*}}{\overline{TP^*}+\overline{FN^*}+\overline{FP^*}+\overline{TN^*}}=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(TS)}\setminus\mathcal{X}_{\mathcal{C}}^{(LS)}\wedge\{\bar{c}_i\}=G(\boldsymbol{z_i})\right\}_{i=1}^{\bar{M}^*}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(TS)}\setminus\mathcal{X}_{\mathcal{C}}^{(LS)}\right\}_{i=1}^{\bar{M}^*}}$$

8. переобученности при классификации:

$$OCR=\overline{CCR}-GCR=\frac{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(LS)}\wedge\{\bar{c}_i\}=G(\boldsymbol{z_i})\right\}_{i=1}^{\bar{M}}}{\#\left\{\boldsymbol{z_i}\middle|\boldsymbol{z_i}\in\bar{\mathcal{X}}_{\mathcal{C}}^{(LS)}\right\}_{i=1}^{\bar{M}}}-GCR$$

Отличия от других методик

- Задание произвольной вложенности классификаторов друг в друга с указанием правил формирования входных данных
- Ленивое подключение классификаторов благодаря наличию алгоритма каскадного обучения узлов
- Гибкое объединение детекторов при помощи различных низкоуровневых схем их комбинирования и агрегирующих композиций

Результаты

Результат 4

Архитектура распределенной СОА, построенной на основе комбинирования сигнатурного анализа и методов ВИ

Архитектура распределенной СОА

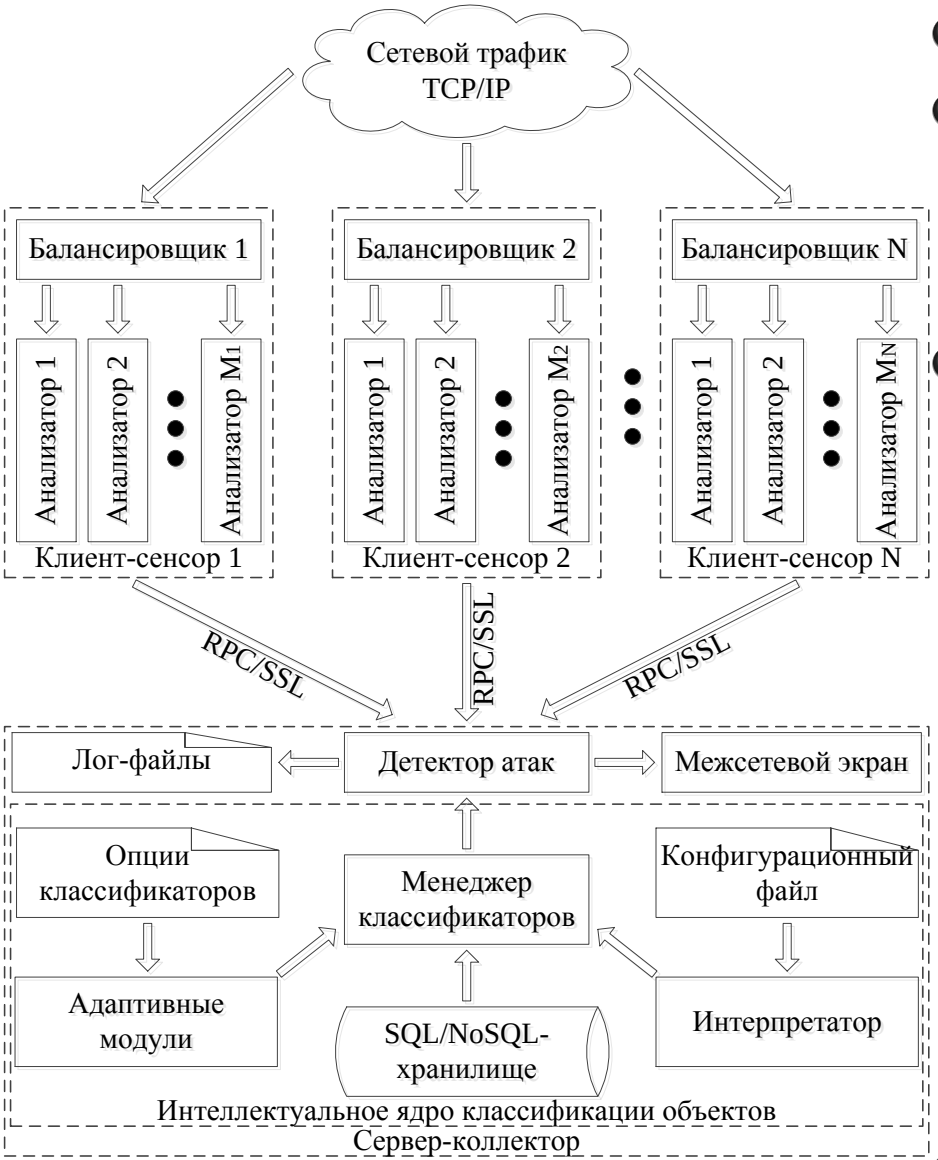

- Клиент-серверная архитектура
- Сенсоры
  - ✓ **Балансировщик трафика**
  - ✓ **Анализаторы трафика**
- Коллектор
  - ✓ **Интерпретатор**
  - ✓ **Адаптивные модули (so-библиотеки)**
  - ✓ **Менеджер классификаторов**
  - ✓ Детектор атак
  - ✓ Межсетевой экран (iptables)
  - ✓ SQL/NoSQL-хранилище (MySQL, MongoDB, CSV)
- Канал на основе RPC/SSL

Балансировщик трафика

1 выходной интерфейс 2 выходных интерфейса

Число отбрасываемых пакетов

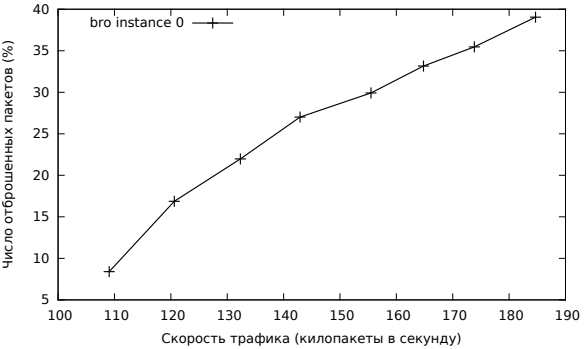

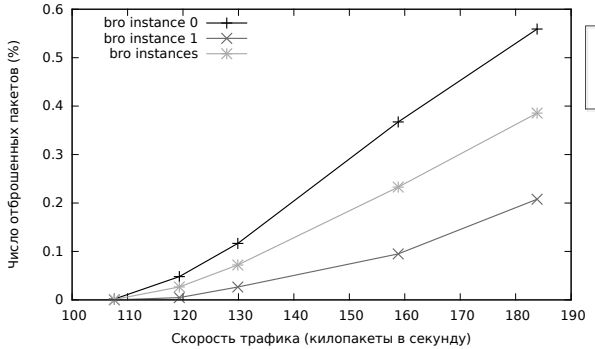

Загруженность процессора

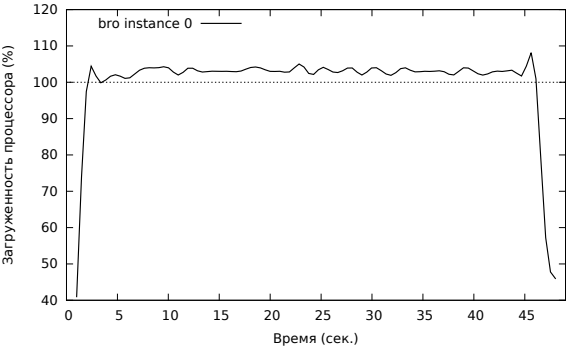

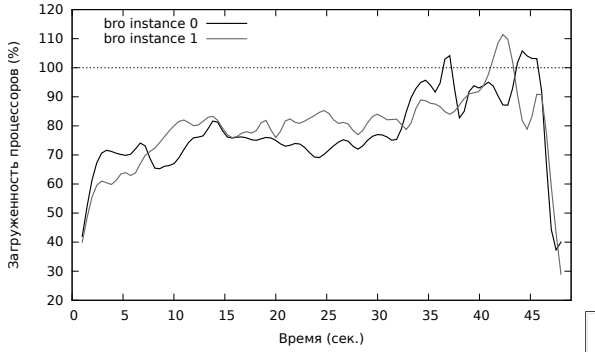

Потребление памяти

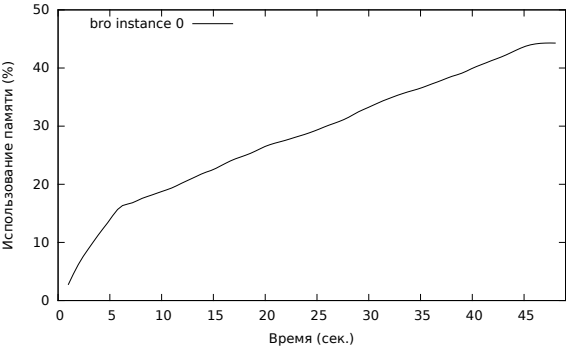

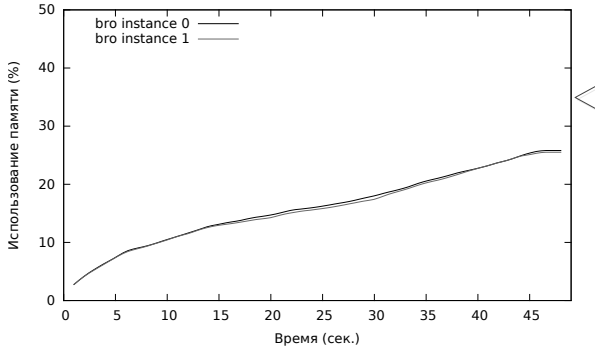

Анализатор трафика

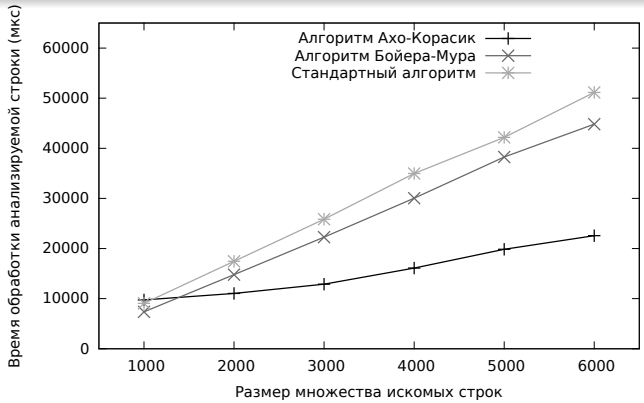

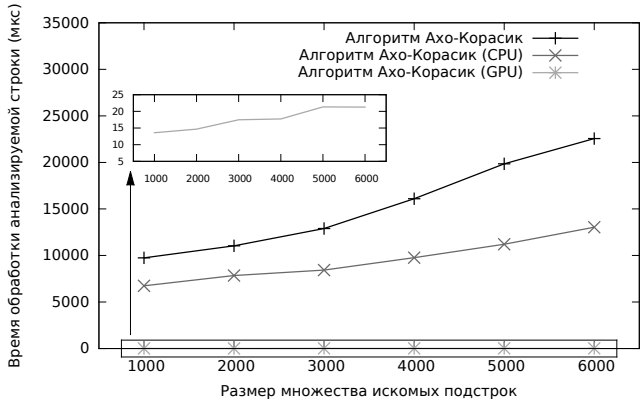

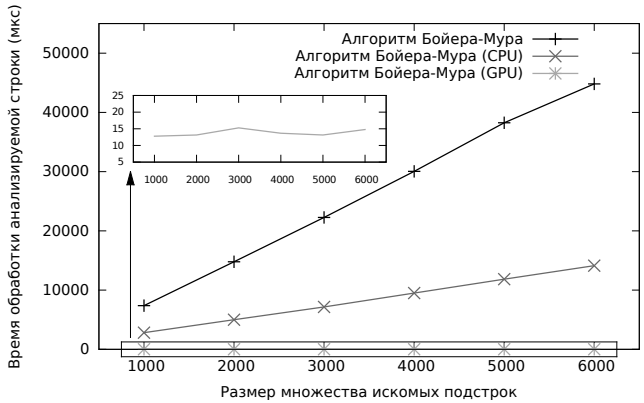

- Поддержка событийно-ориентированного механизма обработки сетевых соединений (32 события)
- Реализация алгоритмов IP-дефрагментации и TCP-реассемблирования, свойственных сетевому стеку ОС Linux (RFC 791, 3128, 793, 7413, 1858, 1071, ...)
- Параллельные модификации алгоритмов поиска шаблонных подстрок в сигнатурных правилах СОА (технологии OpenMP, CUDA)
- 106 сетевых параметров (продолжительность соединения, служба, интенсивность отправки пакетов, число активных соединений, признак изменения масштабирования TCP-окна, состояние соединения, ...)
- Алгоритм преаллокации памяти для хранения fnv-хешированных записей о соединениях
- Наличие API для обнаружения атак со скрытием и со вставкой (Ptacek & Newsham)

Интерпретатор и адаптивные модули

```
classifier_tree: {
  vars: {
    in_dim: {
      "33" }
    out_dim: {
      "6" } }
  classifier: {
    name: {
      "meta_classifier" }
    identifier: {
      "7" }
    so_library: {
      "libmeta_classifier.so" }
    prf_file: {
      "meta_classifier_results.prf" }
    sls_file: {
      "meta_classifier_struct.sls" }
    opt_file: {
      "meta_classifier_options.opt" }
    input_dim: {
      "7" }
    output_dim: {
      "$out_dim" }
    input_data: {
      "concat(sum(idx#4,idx#5),idx#3)" }
    output_data: {
      type: {
        "array" } }
    nested_classifiers: {
      classifier:{
        ... } } } }
```

- Интерпретатор
  - ✓ КС грамматика
  - ✓ Левосторонняя рекурсия
  - ✓ Построение дерева классификаторов
  - ✓ Поддержка операторов условного ветвления, векторной конкатенации, ...
- Адаптивные модули
  - ✓ 20 плагинов
  - ✓ 5 АЯВУ (C, C++, Perl, Python, R)
  - ✓ Маршалинг основных типов данных C в скриптовые объекты и обратно
  - ✓ Динамическое встраивание плагинов в ядро COA без необходимости предлинковки

Менеджер классификаторов

- загрузка классификаторов из плагинов
- вызов функций, определенных в плагинах
- иерархический обход дерева классификаторов

Алгоритм каскадного обучения

```
1  функция f_1 конвертирования дерева классификаторов cls_tree в однонаправленный список dir_list
2  начало блока
3      dir_list :=создать пустой список
4      добавить корень root_node дерева cls_tree в качестве головного элемента в список dir_list
5      list_elem :=получить головной элемент списка dir_list (root_node)
6      пока list_elem не равен NULL выполнять
7          если узел list_elem не является терминальным в дереве cls_tree тогда
8              для каждого дочернего узла nested_node элемента list_elem выполнять
9                  добавить узел nested_node в качестве хвостового элемента в список dir_list
10         list_elem :=получить следующий за list_elem элемент из списка dir_list
11     возвратить dir_list
12 функция f_2 каскадного обучения узла node и его зависимостей в дереве классификаторов cls_tree
13 начало блока
14     если узел node помечен как необученный тогда
15         если узел node нетерминальный тогда
16             для каждого узла dep_node из списка зависимостей узла node выполнять
17                 вызвать функцию f_2 для узла dep_node
18         in_data :=сформировать входные векторы для узла node согласно его дереву выражений
19         выполнить обучение классификатора, размещенного в узле node, на данных in_data
20         пометить узел node как обученный
21 функция f_3 обхода дерева классификаторов cls_tree в ширину при помощи списка dir_list
22 начало блока
23     node :=получить головной элемент списка dir_list
24     пока node не равен NULL выполнять
25         вызвать функцию f_2 для узла node
26         node :=получить следующий за node элемент из списка dir_list
27 cls_tree :=вызвать интерпретатор для заданного пользователем конфигурационного файла
28 dir_list :=вызвать функцию f_1 для дерева классификаторовcls_tree
29 вызвать функцию f_3 для дерева классификаторов cls_tree и списка dir_list
```

Отличия от других архитектур

- Реализация оригинальной методики иерархической гибридизации бинарных классификаторов для обнаружения аномальных сетевых соединений
- Возможность горячей вставки нового исполняемого кода за счет загрузки плагинов, представленных в виде so-библиотек и встраиваемых динамически в ядро COA
- Наличие интерпретатора с возможностью написания собственных сценариев для задания структуры и правил функционирования адаптивных классификаторов и отдельных детекторов

Заключение по результатам

Основные результаты:

1. Разработана **модель вычислительной иммунной системы на базе эволюционного подхода**. Модель характеризуется наличием двухуровневой процедуры обучения и тестирования и позволяет учитывать динамическую природу сетевого трафика посредством переобучения иммунных детекторов как с течением времени, так и в ответ на выявленные в сетевом трафике аномалии.
2. Разработан **алгоритм генетико-конкурентного обучения сети Кохонена**. Отличительной особенностью алгоритма является наличие процесса имитации эволюции мертвых нейронов, который достигается за счет использования нескольких стратегий генетической оптимизации весовых коэффициентов сети Кохонена.
3. Разработана **методика иерархической гибридизации бинарных классификаторов**. Методика предоставляет возможность строить комбинирующие схемы с произвольной вложенностью классификаторов друг в друга и их ленивым подключением в процессе анализа входного вектора.
4. Разработана **архитектура гибридной СОА, построенной на основе комбинирования сигнатурного анализа и методов ВИ**. СОА обеспечивает возможность горячей вставки исполняемого кода за счет загрузки плагинов, представленных в виде so-библиотек и встраиваемых динамически в ядро СОА.

Публикации (ВАК)

В журналах, рекомендованных ВАК:


Браницкий А. А., *Котенко И. В.* — Обнаружение сетевых атак на основе комплексирования нейронных, иммунных и нейронечетких классификаторов. — // Информационно-управляющие системы. — 2015. — 4 (77). — С. 69—77.


Браницкий А. А., *Котенко И. В.* — Построение нейросетевой и иммуноклеточной системы обнаружения вторжений. — // Проблемы информационной безопасности. Компьютерные системы. — 2015. — № 4. — С. 23—27.


Браницкий А. А., *Котенко И. В.* — Анализ и классификация методов обнаружения сетевых атак. — // Труды СПИИРАН. — 2016. — 2 (45). — С. 207—244.


Браницкий А. А. — Иерархическая гибридизация бинарных классификаторов для выявления аномальных сетевых соединений. — // Труды СПИИРАН. — 2017. — 3 (52). — С. 204—233.


Браницкий А. А., *Котенко И. В.* — Открытые программные средства для обнаружения и предотвращения сетевых атак. — // Защита Информации. Инсайд. — 2017. — 2 (74). — С. 40—47.


Браницкий А. А., *Котенко И. В.* — Открытые программные средства для обнаружения и предотвращения сетевых атак (окончание). — // Защита Информации. Инсайд. — 2017. — 3 (75). — С. 58—66.

Публикации (прочие)

В прочих изданиях:

Тимофеев А. В., *Браницкий А. А.* — Исследование и моделирование нейросетевого метода обнаружения и классификации сетевых атак. — // International Journal Information Technologies & Knowledge. — 2012. — Т. 6, № 3. — С. 257—265.

Branitskiy A., *Kotenko I.* — Network attack detection based on combination of neural, immune and neuro-fuzzy classifiers. — // In Proceedings of the 18th IEEE International Conference on Computational Science and Engineering (IEEE CSE2015). — IEEE. Окт. 2015. — С. 152—159.

Branitskiy A., *Kotenko I.* — Hybridization of computational intelligence methods for attack detection in computer networks. — // Journal of Computational Science. — 2016.

Branitskiy A., *Kotenko I.* — Network Anomaly Detection Based on an Ensemble of Adaptive Binary Classifiers. — // In Proceedings of International Conference on Mathematical Methods, Models, and Architectures for Computer Network Security. — Springer. 2017. — С. 143—157.

Свидетельства о регистрации программ для ЭВМ

Браницкий А. А., *Котенко И. В.* — Адаптивная система обнаружения атак на основе гибридизации методов вычислительного интеллекта. — Свидетельство о государственной регистрации программы для ЭВМ № 2015662189. Зарегистрировано в Реестре программ для ЭВМ 18.11.2015.

Браницкий А. А., *Котенко И. В.* — Компонент классификации аномальных сетевых соединений на основе искусственных иммунных систем. — Свидетельство о государственной регистрации программы для ЭВМ № 2016663476. Зарегистрировано в Реестре программ для ЭВМ 08.12.2016.

Браницкий А. А., *Котенко И. В.*, *Саенко И. Б.* — Frontend-интерфейс генератора сетевых атак. — Свидетельство о государственной регистрации программы для ЭВМ № 2017660184. Зарегистрировано в Реестре программ для ЭВМ 19.09.2017.