

Методы инспекции пакетов и анализа трафика

Лекция 6 Принцип работы DPI

Фицов Вадим Владленович

ст.преп. кафедры ИКС

Содержание лекции:

- **Потоки трафика**
- **Виды глубокого анализа трафика**
- **Сигнатурный анализа**
- **Поведенческий анализ**
- **Статистический анализ**
- **Эвристический анализ**
- **DataMining анализ**

Потоки трафика

7 tuples (кортеж 7)


Поток идентифицируется с помощью адресной информации 2–4 уровней.

Критерии, по которым пакет относят к потоку, называют кортежем (tuple).

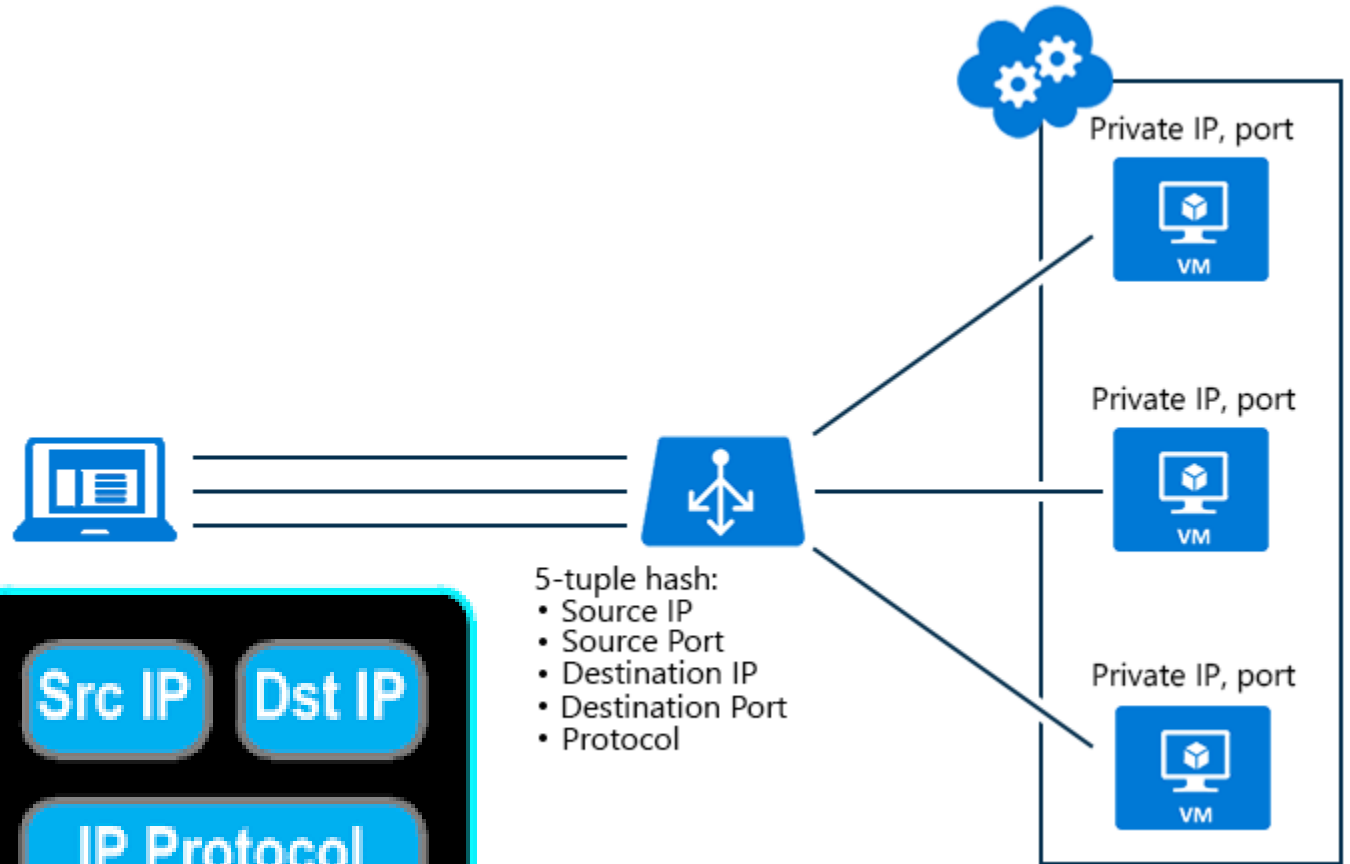
В кортеж может входить разное число критериев, обычно от 3 до 7: MAC-адреса отправителя и получателя, IP-адреса отправителя и получателя, транспортные порты отправителя и получателя, а также значение служебного поля «Тип протокола».

Network-
Layer
Metadata

Transport-
Layer
Metadata



7 tuples (кортеж 7)



Network-
Layer
Metadata

Src IP Dst IP

IP Protocol

5-tuple

Src
Port

Dst
Port

Transport-
Layer
Metadata

Анализ:

- распределение по типам протоколов (% , кол-во пакетов, кол-во байт, скорость)
- распределение по длине кадров
- расчет скорости для каждого протокола
- построение графиков (пакетов/с, бит/с)
- список сайтов к которым обращаются HTTP запросы
- распределение количества пакетов по IP адресам
- обнаружение udp multicast

Виды глубокого анализа трафика

DPI средства управления трафиком



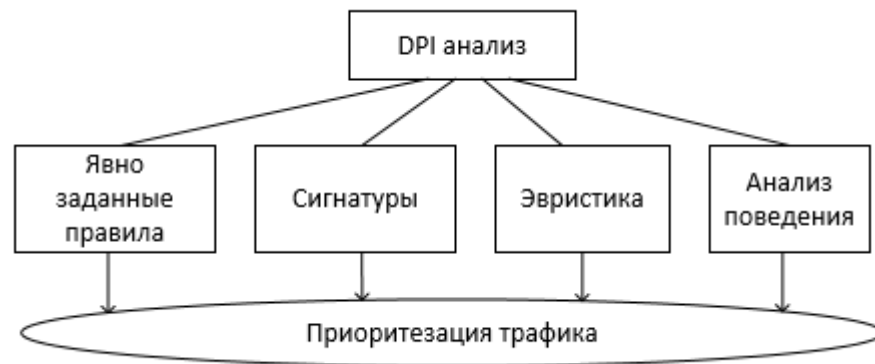
Что происходит при DPI?

DPI анализирует

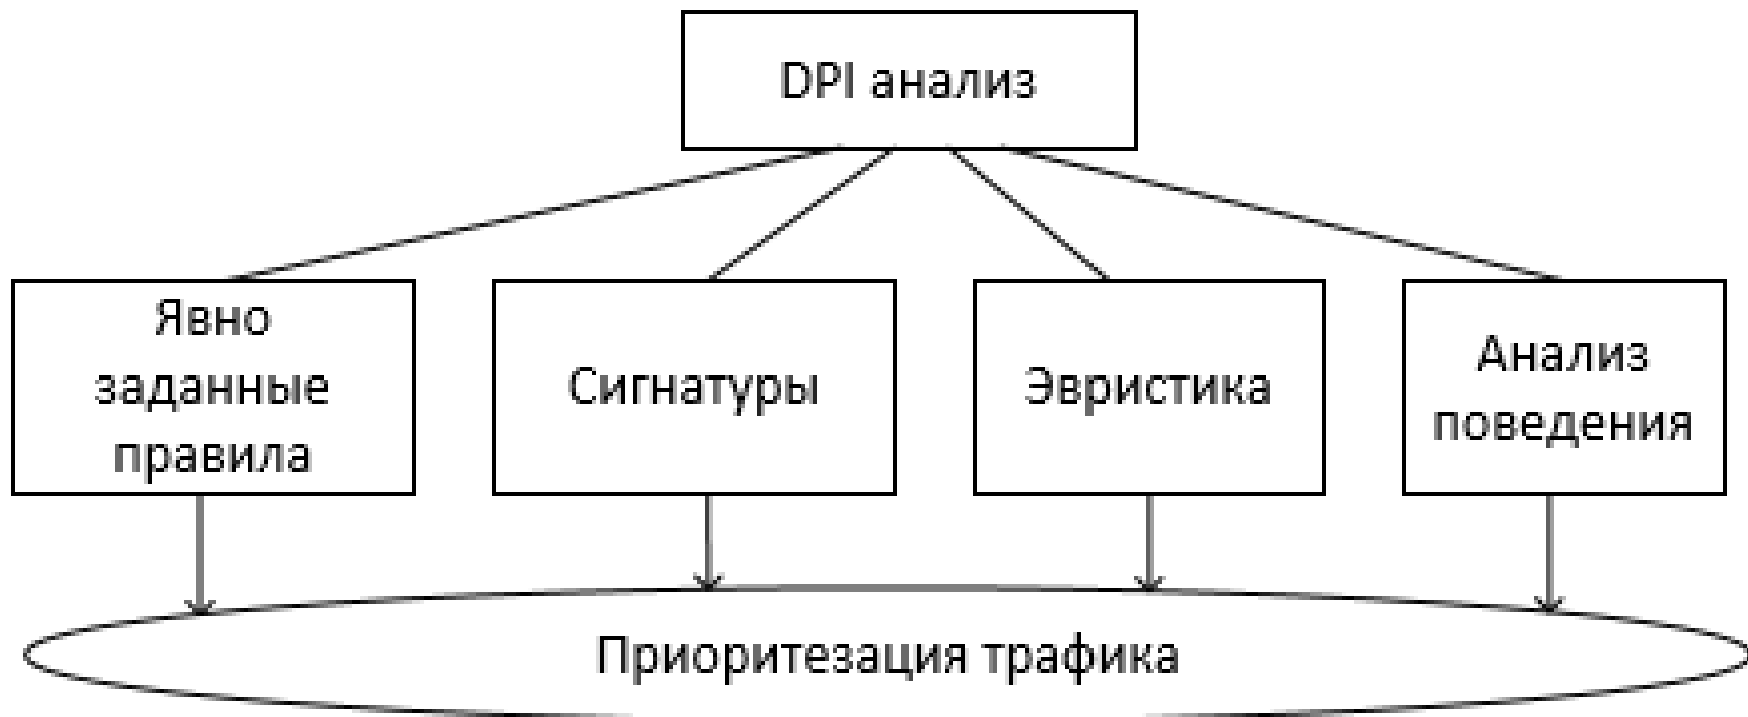
- первые пакеты потока трафика
- или все проходящие через нее пакеты.

- Применяются:

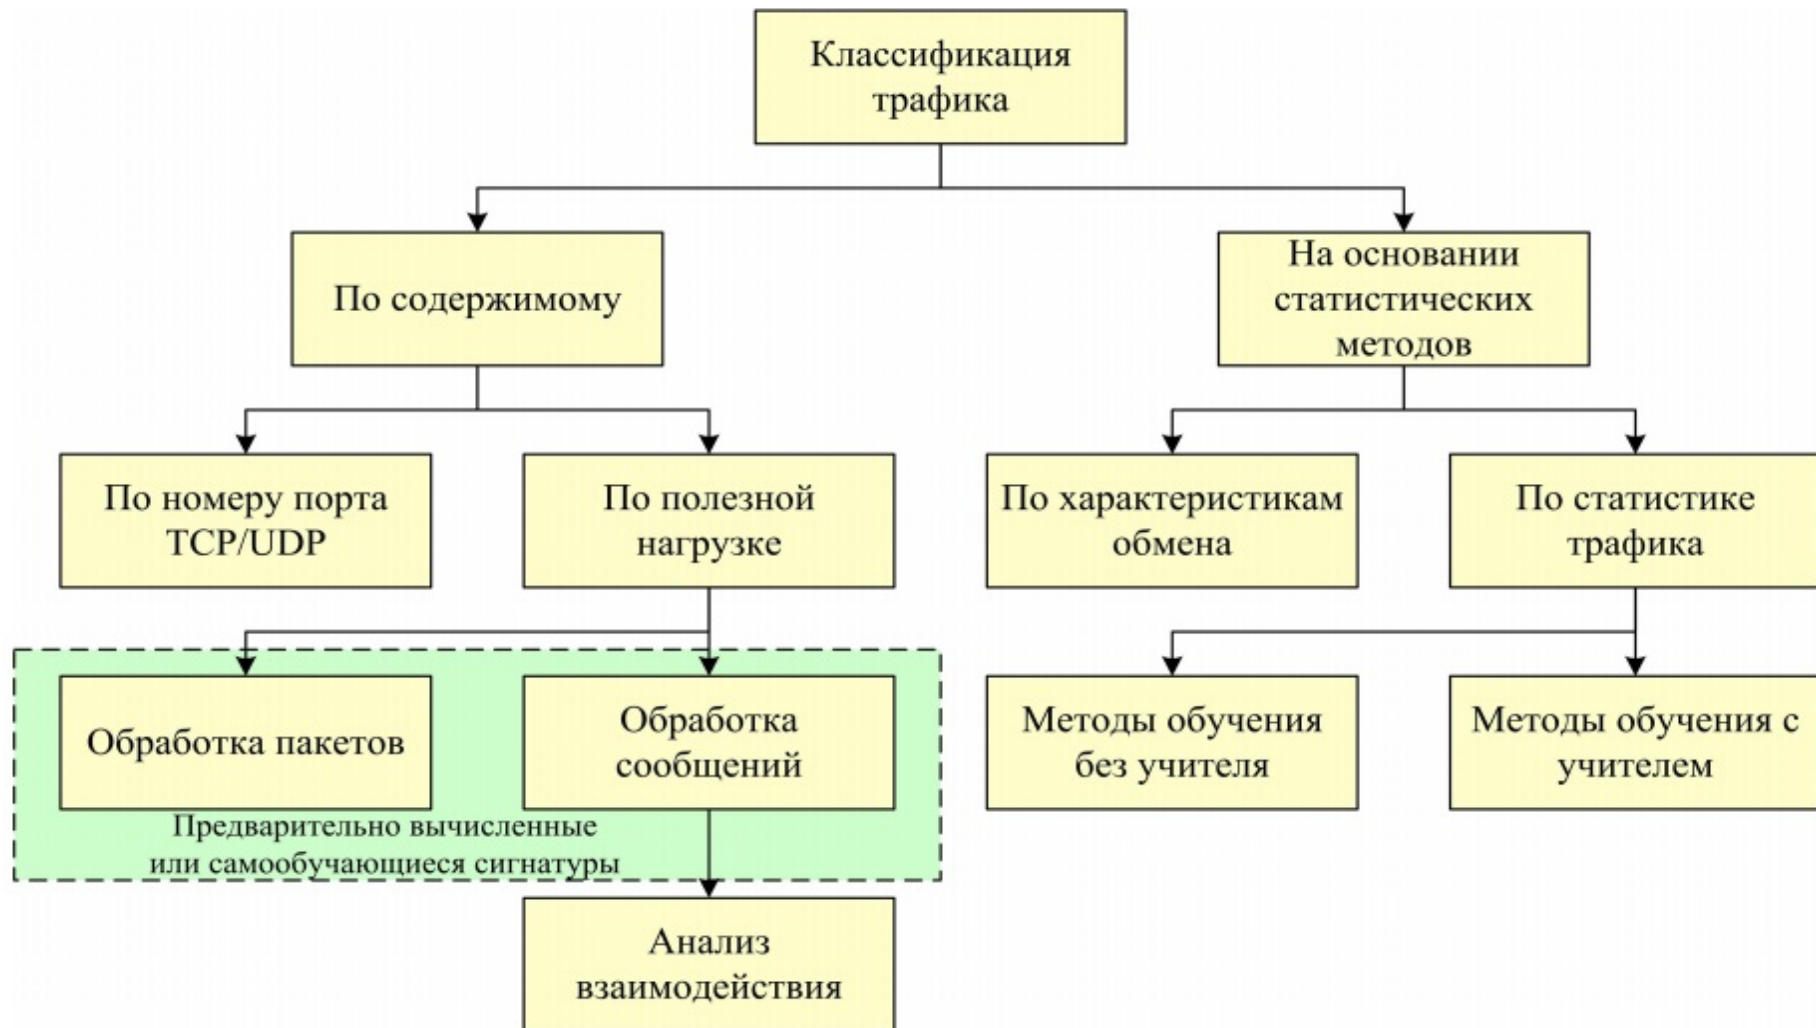
- сигнатурный анализ,
- статистические методы слежения за характеристиками пакетов,
- поведенческий анализ и др.

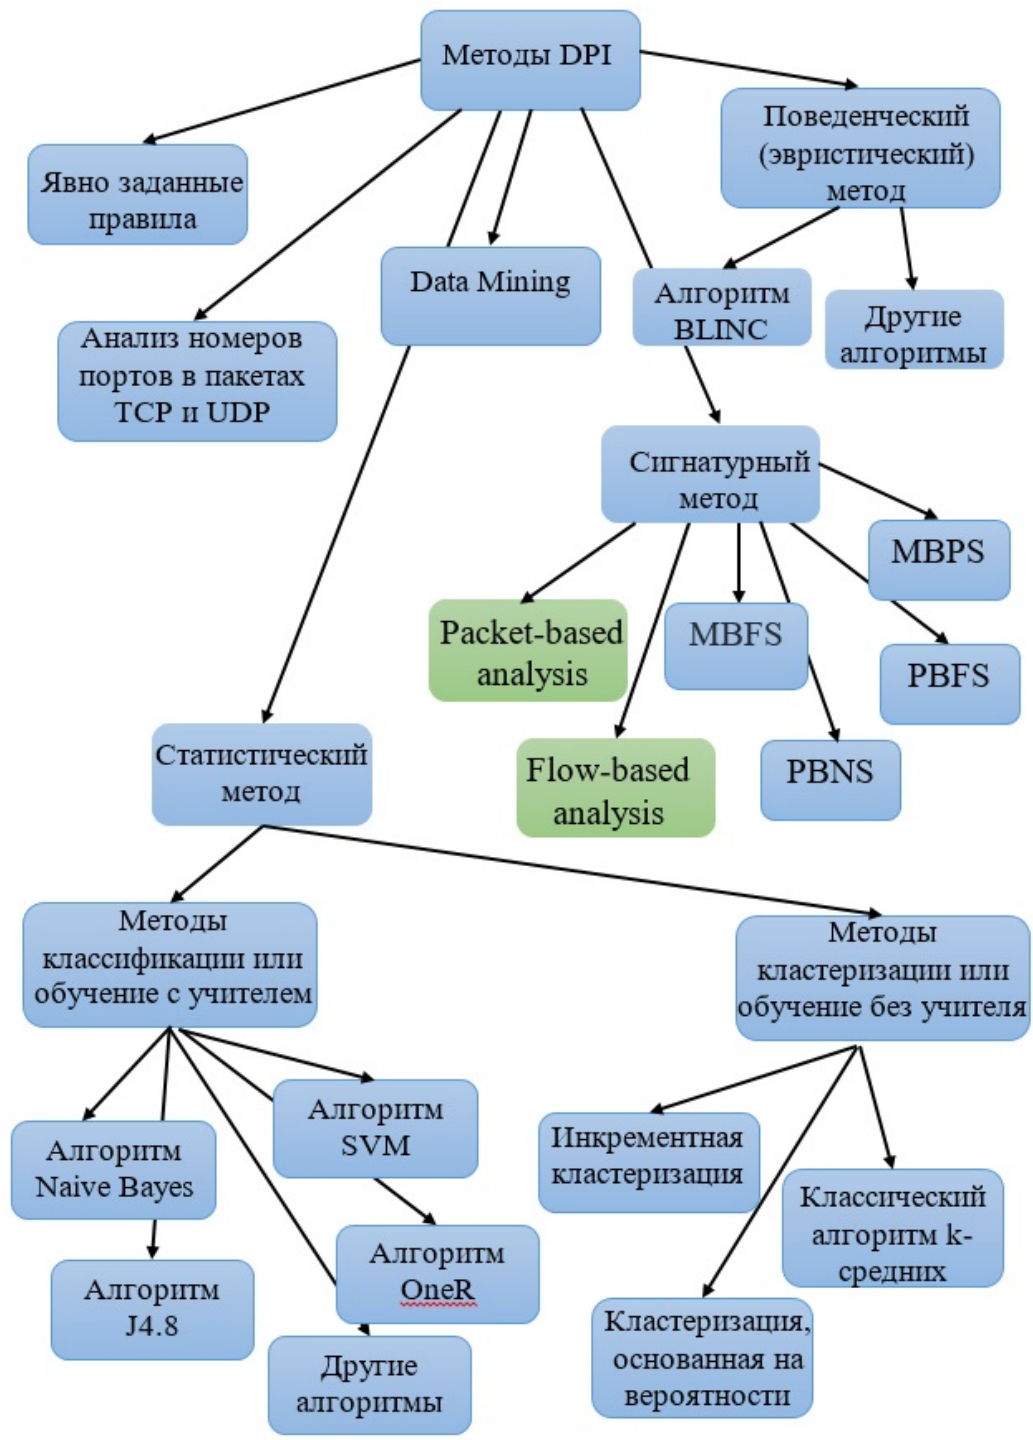


Что происходит при DPI?



Методы классификации сетевого трафика





Сигнатурный анализ

Сигнатурный анализ

Сигнатура – это набор байтов в пакете или файле, позволяющий однозначно определить, к какому приложению, протоколу относится трафик, и классифицировать его.

Сигнатуры разрабатываются и распространяются вендором.

Базу сигнатур необходимо обновлять автоматически или вручную.

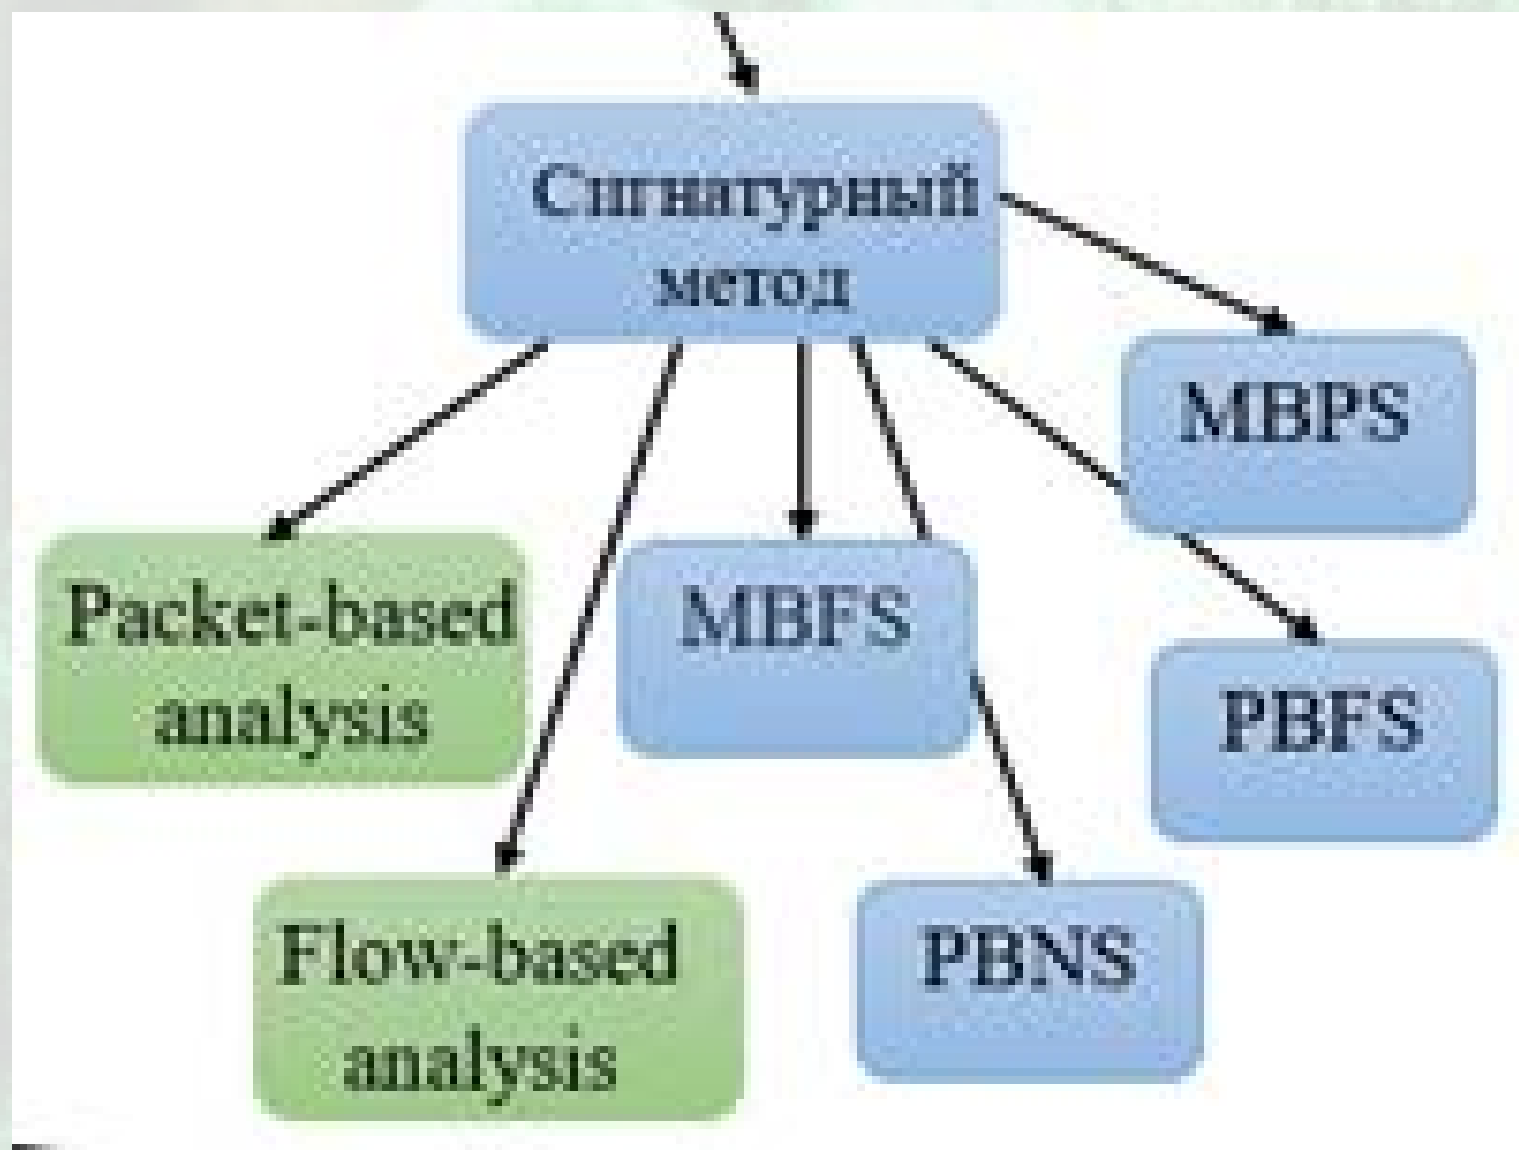
Сигнатурный анализ

стандартные паттерны (например, HEX), по которым можно однозначно определить принадлежность пакета определенному приложению.

Например:

- по формату заголовков,
- номерам портов и т. п.

Сигнатурный анализ



Сигнатурный анализ

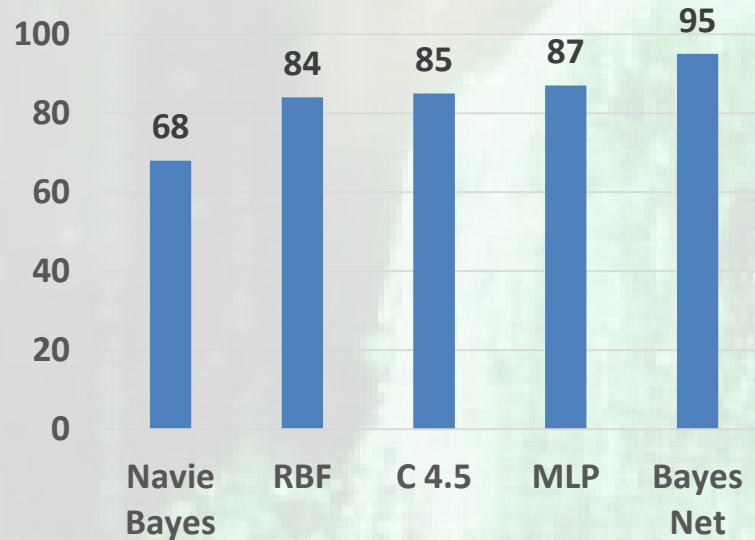
	Скорость сравнения в зависимости от синтаксиса сигнатур, с.		
Алгоритм	Фиксированный фрагмент	Плавающий фрагмент	Регулярные выражения
Rabin-Karp	0,03	1,28	3,45
DFA	0,05	0,32	0,19
NFA Full	0,08	0,42	0,16
NFA Particial		0,90	0,08

Сигнатурный анализ


Тип сигнатуры	Сигнатура	Время сравнения при DFA Full, с.	Время сравнения при NFA Partial, с.
SSSA	^GET.*NateOn.*	0,23	0,05
	^GET.*nateon\.nate\.com.*	0,22	0,06
	^GET.*adimg\.nate\.com.*	0,18	0,11
	^GET.*cyad\.nate\.com.*	0,25	0,15
	^GET.*nateonipml\.nate\.com.*	0,21	0,10
MSSA	^GET.*(NateOn) (nateon\.nate\.com) (adimg\.nate\.com) (cyad\.nate\.com) (nateonipml\.nate\.com).*	0,22	9,24

Анализ результатов исследования алгоритмов машинного обучения


Точность классификации, %



Верность



Время обучения, с



Сигнатурный анализ

Трафик SPB TV

6



Перехват трафика



SPB TV IP 91.228.177.0
193.160.158.0

Client IP 95.221.67.9



CPU: 2.50 MHz
2 ядра



Port 57124



Port 80



Port 57150



Port 80



Port 57162



Port 80



Сигнатурный анализ



Host: 91.228.177.209

(Router/AccessPoint) MAC Address: CiscoInc_27:A2:40 (44:03:A7:27:A2:40)

IP Address: 91.228.177.209 [Moscow]

ASN: SPB TV Telecom LLC [ASN 197888]

Name: 91.228.177.209

First / Last Seen: 05/06/2017 23:52:07 [3 min, 16 sec ago] / 05/06/2017 23:55:19 [4 sec ago]

Sent vs Received Traffic Breakdown: Sent

Traffic Sent / Received: 24,698 Pkts / 32.91 MB ↑ / 14,910 Pkts / 1.13 MB ↑

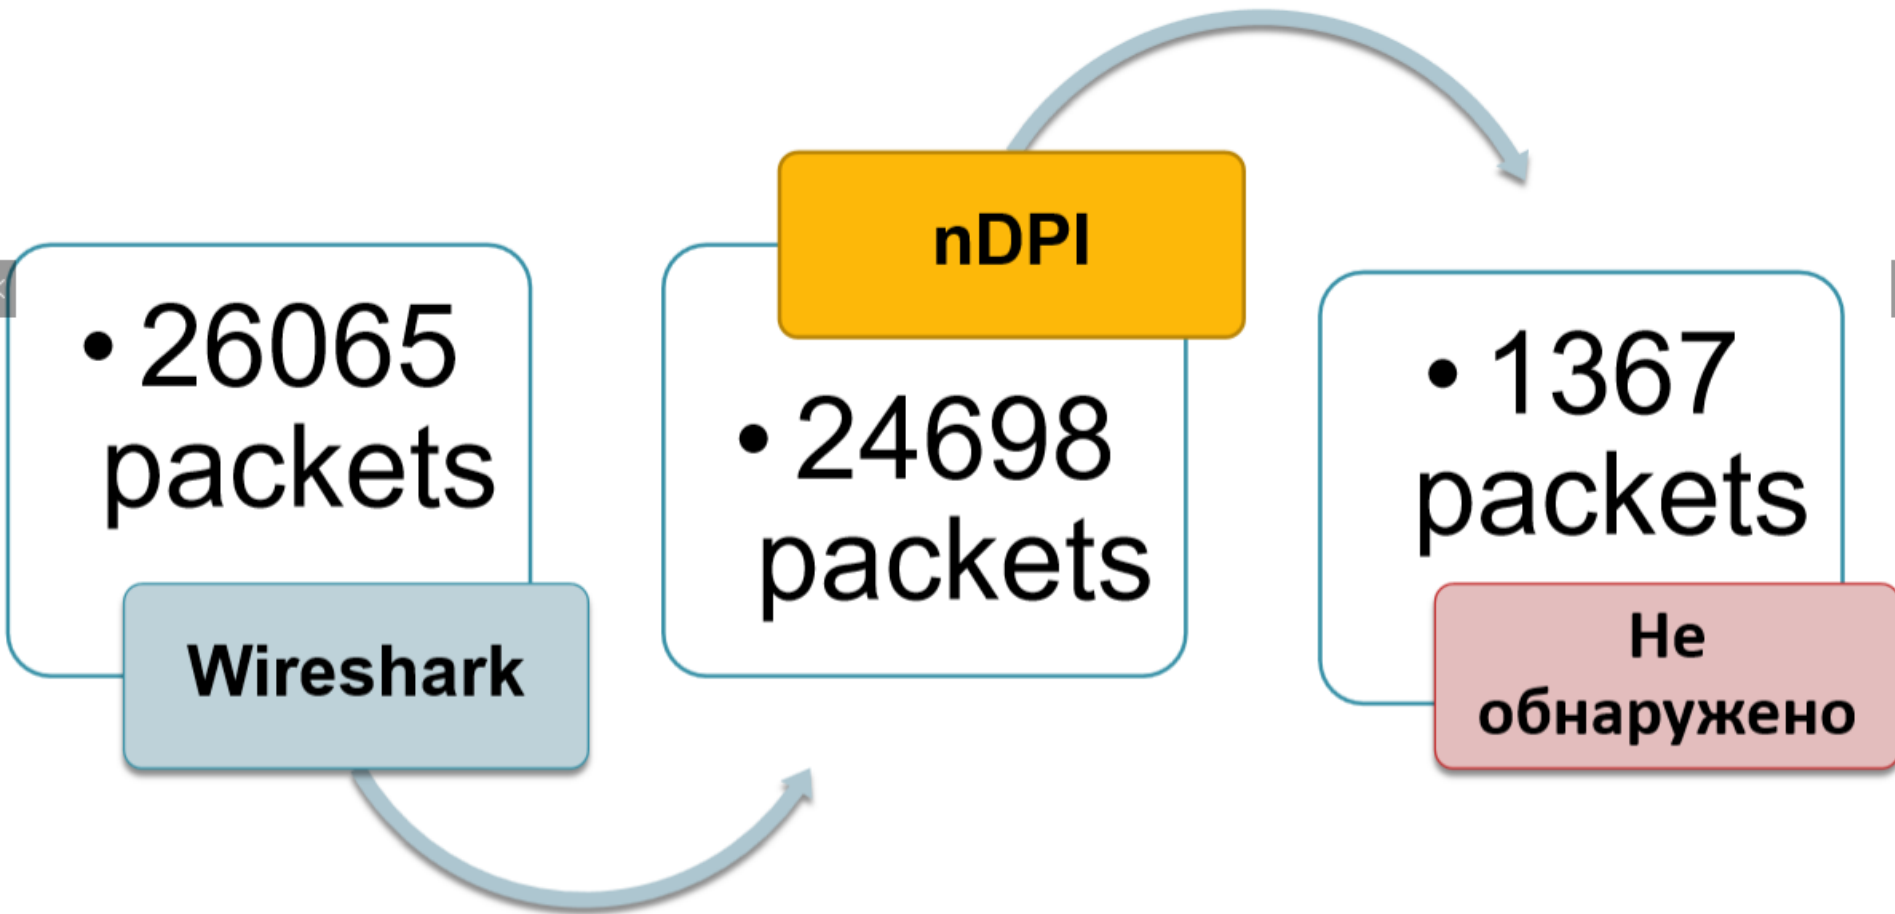
Active Flows / Total Active / Low Goodput: 'As Client' 0 / 2 / 0 / 'As Server' 2 / 14 / 0

TCP Packets Sent Analysis: Retransmissions 0 Pkts, Out of Order 81 Pkts, Lost 38 Pkts

Further Host Names/Information: 91.228.177.209


JSON: Download

Сигнатурный анализ



Сигнатурный анализ

No.	Time	Source	Destination	Protocol	Length	Info
361	0.000436	95.221.67.9	81.19.88.103	HTTP	517	GET /top100.jcn?2815224 HTTP/1.1
362	0.002055	95.221.67.9	178.154.131.215	TCP	62	57143 → 443 [ACK] Seq=328 Ack=6303 Win=65776 Len=0
363	0.010957	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
364	0.000364	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
365	0.000005	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
366	0.000004	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
367	0.000131	95.221.67.9	81.19.88.103	TCP	62	57146 → 80 [ACK] Seq=456 Ack=2721 Win=65280 Len=0
368	0.000109	95.221.67.9	81.19.88.103	TCP	62	57146 → 80 [ACK] Seq=456 Ack=5441 Win=65280 Len=0
369	0.000139	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
370	0.000004	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
371	0.000010	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
372	0.000016	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
373	0.000098	95.221.67.9	81.19.88.103	TCP	62	57146 → 80 [ACK] Seq=456 Ack=8161 Win=65280 Len=0
374	0.000098	95.221.67.9	81.19.88.103	TCP	62	57146 → 80 [ACK] Seq=456 Ack=10881 Win=65280 Len=0
375	0.001072	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]
376	0.000005	81.19.88.103	95.221.67.9	TCP	1422	[TCP segment of a reassembled PDU]

(Router/AccessPoint) MAC Address	ZyxeICom_94:D6:00 (E8:37:7A:94:D6:00)	
IP Address	91.228.177.207 [Moscow 🇷🇺]	Host Pool: Not Assigned ⚙
ASN	SPB TV Telecom LLC [ASN 197888]	Whois Lookup 🔗
Name	91.228.177.207 🌐 ⚙ Remote	
First / Last Seen	15/06/2017 12:10:56 [1 min, 1 sec ago]	15/06/2017 12:11:52 [5 sec ago]
Sent vs Received Traffic Breakdown		Sent
Traffic Sent / Received	2,755 Pkts / 3.65 MB —	971 Pkts

Сигнатурный анализ

Последовательность в HEX: 48 54 54 50 2f 31 2e 31
20 32 30 30 20 4f 4b 0d 0a 58 2d 50 6f 77 65 72 65 64
2d 42 79 3a 20 50 48 50 2f 35 2e 35 2e 33 38 0d 0a

Wireshark · Packet 323 · вместе с nDPI

- ▶ Frame 323: 1422 bytes on wire (11376 bits), 1422 bytes captured (11376 bits) on interface 0
- ▶ Ethernet II, Src: Cisco_27:a2:40 (44:03:a7:27:a2:40), Dst: CompalIn_4a:3e:b9 (20:89:84:4a:3e:b9)
- ▶ PPP-over-Ethernet Session
- ▶ Point-to-Point Protocol
- ▶ Internet Protocol Version 4, Src: 91.218.229.131, Dst: 95.221.67.9
- ▶ Transmission Control Protocol, Src Port: 80, Dst Port: 57134, Seq: 1, Ack: 614, Len: 1360

0030	37 a9 cc e3 16 03 50 10 00 7c 1e 32 00 00 48 54	7....P. . .2..HT
0040	54 50 2f 31 2e 31 20 32 30 30 20 4f 4b 0d 0a 58	TP/1.1 2 00 OK..X
0050	2d 50 6f 77 65 72 65 64 2d 42 79 3a 20 50 48 50	-Powered -By: PHP
0060	2f 35 2e 35 2e 33 38 0d 0a 45 78 70 69 72 65 73	/5.5.38. .Expires
0070	3a 20 4d 6f 6e 2c 20 30 35 20 4a 75 6e 20 32 30	: Mon, 0 5 Jun 20
0080	31 37 20 32 31 3a 35 32 3a 30 39 20 47 4d 54 0d	17 21:52 :09 GMT.
0090	0a 50 72 61 67 6d 61 3a 20 6e 6f 2d 63 61 63 68	.Pragma: no-cach
00a0	65 0d 0a 43 61 63 68 65 2d 43 6f 6e 74 72 6f 6c	e..Cache -Control
00b0	3a 20 70 75 62 6c 69 63 2c 20 6d 61 78 2d 61 67	: public , max-ag
00c0	65 3d 33 36 30 30 0d 0a 43 6f 6e 74 65 6e 74 2d	e=3600.. Content-

Сигнатурный анализ

Filter: **bittorrent** Expression... Clear Apply Save

No.	Time	Source	Destination	Protocol	Length	Info
387	1.135728000	192.168.1.107	37.147.15.107	BitTorrent	122	Handshake
392	1.137129000	192.168.1.107	37.113.150.167	BitTorrent	122	Handshake
405	1.142739000	192.168.1.107	188.234.89.226	BitTorrent	122	Handshake

Frame 387: 122 bytes on wire (976 bits), 122 bytes captured (976 bits) on interface 0

- Ethernet II, Src: AsustekC_1a:10:f8 (ac:22:0b:1a:10:f8), Dst: Tp-LinkT_a9:53:8c (74:ea:3a:a9:53:8c)
- Internet Protocol Version 4, Src: 192.168.1.107 (192.168.1.107), Dst: 37.147.15.107 (37.147.15.107)
- Transmission Control Protocol, Src Port: 65533 (65533), Dst Port: 58572 (58572), Seq: 1, Ack: 1, Len: 68
- BitTorrent
 - Protocol Name Length: 19
 - Protocol Name: BitTorrent protocol
 - Reserved Extension Bytes: 0000000000100005
 - SHA1 Hash of info dictionary: 98c8806b1f8b06cd438f6bcf42775d64988c4299
 - Peer ID: 2d5554333432302dde8d586dce2b966b9c868d0e

0000	74	ea	3a	a9	53	8c	ac	22	0b	1a	10	f8	08	00	45	00	t...S..."E.
0010	00	6c	37	2f	40	00	80	06	cc	4b	c0	a8	01	6b	25	93	.17/0... .K...k%	
0020	0f	6b	ff	fd	e4	cc	82	b7	01	de	26	01	a0	f7	50	18	.k..... &...P.	
0030	01	00	96	2f	00	00	13	42	69	74	54	6f	72	72	65	6e	.../...B itTorren	
0040	74	20	70	72	6f	74	6f	63	6f	6c	00	00	00	00	10		t protoc ol.....	
0050	00	05	98	c8	80	6b	1f	8b	06	cd	43	8f	6b	cf	42	77k... .C.k.Bw	
0060	5d	64	98	8c	42	99	2d	55	54	33	34	32	30	2d	de	8d	Id..B.-u T3420...	
0070	58	6d	ce	2b	96	6b	9c	86	8d	0e							kn.+k....	

Рис. 2.10. Пакет BitTorrent, полученный с помощью Wireshark

Сигнатурный анализ

Заголовок BitTorrent при рукопожатии имеет следующий формат:

<acharacter (1 byte)> <astring (19 byte)>.

Первый байт всегда фиксирован и имеет значение «19»,

а значение строки – «BitTorrent protocol».

Исходя из анализа поля данных, происходит идентификация BitTorrent-трафика:

- 1) первый байт в полезной нагрузке TCP-9 (0x13);
- 2) следующие 19 байт соответствуют строке «BitTorrent protocol».

Сигнатурный анализ

Таблица 2.1

Формат правила политики для трафика протокола BitTorrent

Правило политики для трафика BitTorrent	
Условие	Действие
ЕСЛИ: У1: «L4+Тип протокола = TCP» И У2: «Первый байт в поле данных TCP = 0x13» И У3: «Следующие 19 байт в поле данных TCP = «BitTorrent protocol»»	ТОГДА: Д1: «Присвоить низший приоритет»

Сигнатурный анализ

Таблица 2.2

Формат правила политики для трафика протокола HTTP

Правило политики для трафика HTTP	
Условие	Действие
ЕСЛИ: У1: «L4+Тип протокола = TCP» И У2: «Поле данных TCP = «GET» или «POST» или «HEAD» + «HTTP/»»	ТОГДА: Д1: «Присвоить приоритет»

Сигнатурный анализ SSH

```
if (flow->l4.tcp.ssh_stage == 0) {
    if (packet->payload_packet_len > 7 && packet->payload_packet_len < 100
        && memcmp(packet->payload, "SSH-", 4) == 0) {
        NDPI_LOG(NDPI_PROTOCOL_SSH, ndpi_struct, NDPI_LOG_DEBUG, "ssh stage 0 passed\n");
        flow->l4.tcp.ssh_stage = 1 + packet->packet_direction;
        return;
    }
} else if (flow->l4.tcp.ssh_stage == (2 - packet->packet_direction)) {
    if (packet->payload_packet_len > 7 && packet->payload_packet_len < 100
        && memcmp(packet->payload, "SSH-", 4) == 0) {
        NDPI_LOG(NDPI_PROTOCOL_SSH, ndpi_struct, NDPI_LOG_DEBUG, "found ssh\n");
        ndpi_int_ssh_add_connection(ndpi_struct, flow);
        return;
    }
}
```

Поведенческий анализ

Поведенческий анализ

распознает приложения, без заранее известных заголовков и структуры данных.

Например – BitTorrent.

Применяется анализ последовательности пакетов, принадлежащих к одному потоку.

Поведенческий анализ

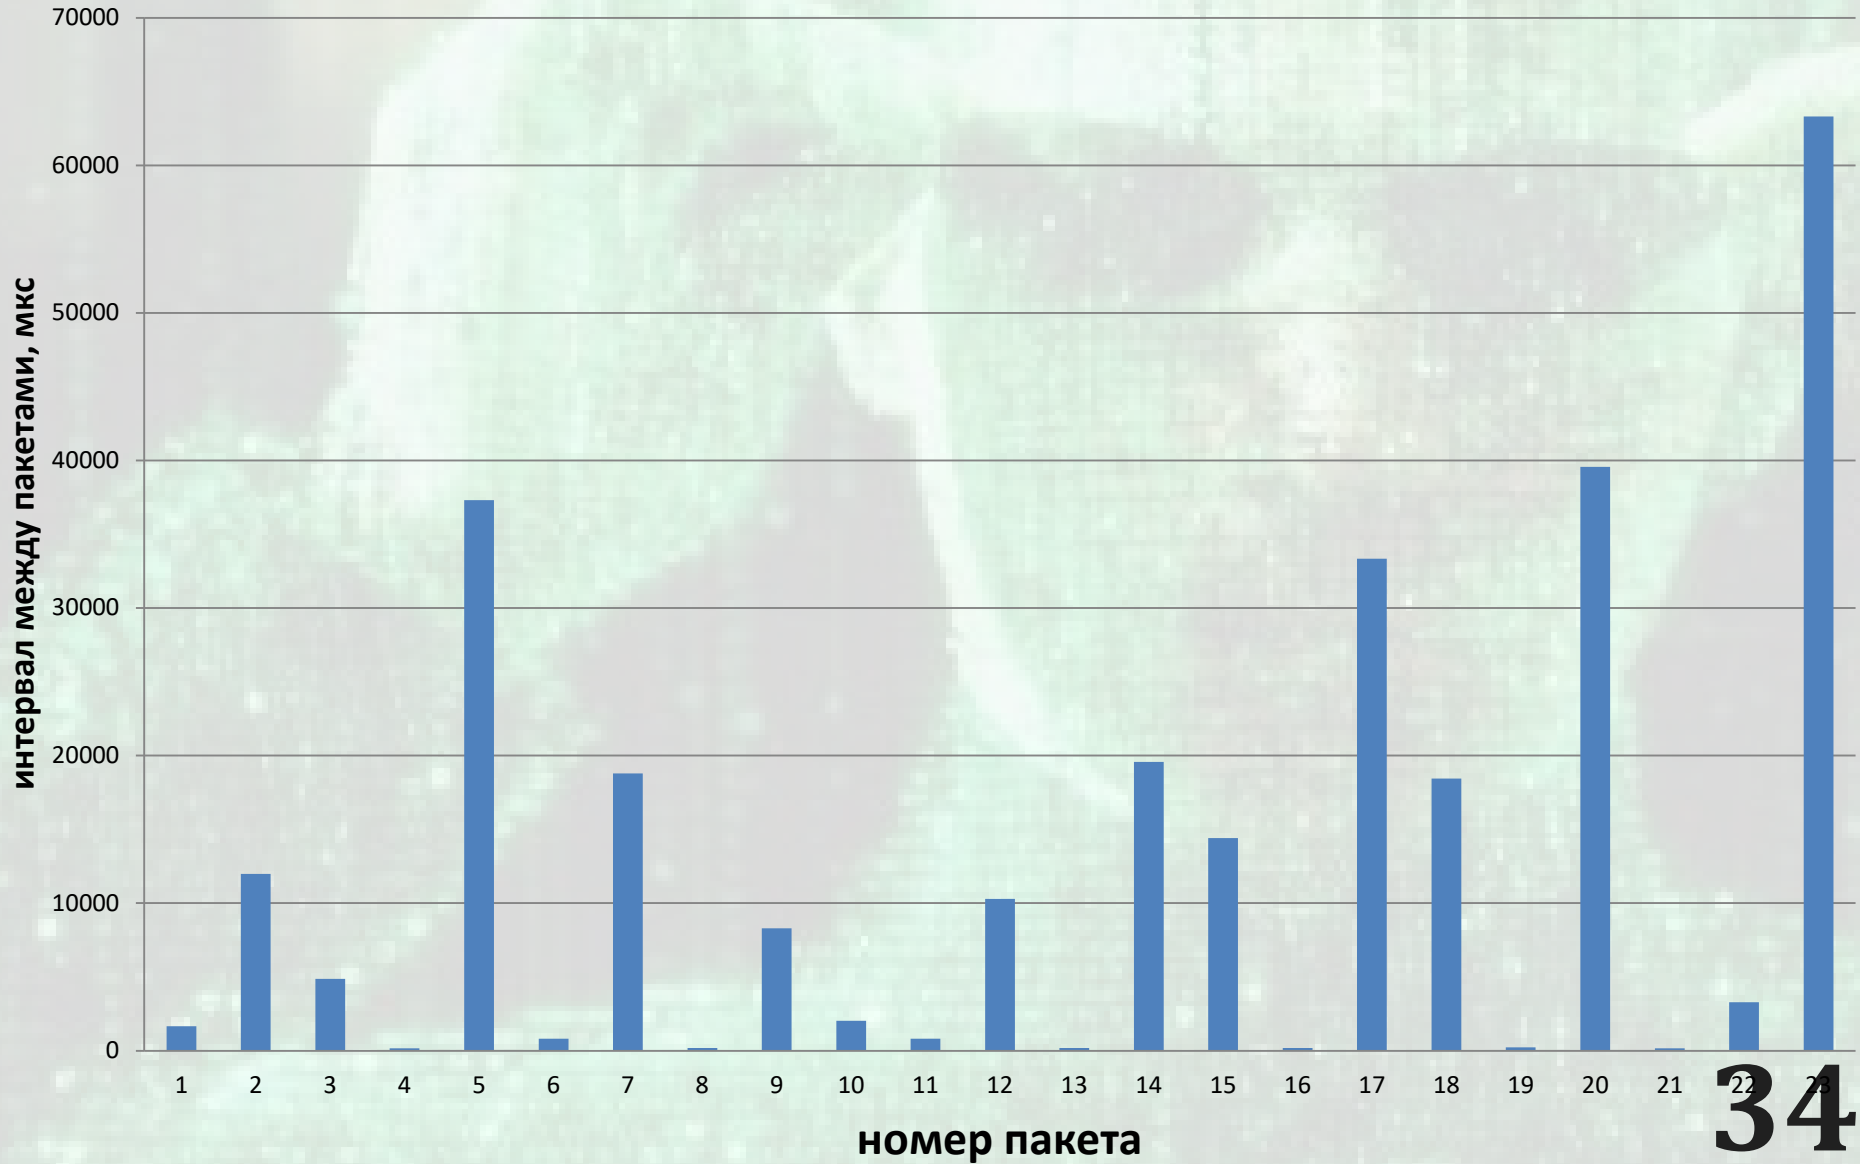
- транспортные порты отправителя и получателя,
- размер пакета,
- частота открытия новых сессий в единицу времени...

Существует множество поведенческих моделей соответствующих протоколов и приложений.

Точность определения различается.

Поведенческий анализ


Включение видео



34

Поведенческий анализ

Фрагмент видео



```
(((p.src == 95.221.91.239) && (tcp.sport == 57247)) or ((p.dstport == 57247) && (p.src == 91.228.177.209))) && (frame.len == 1422)
```

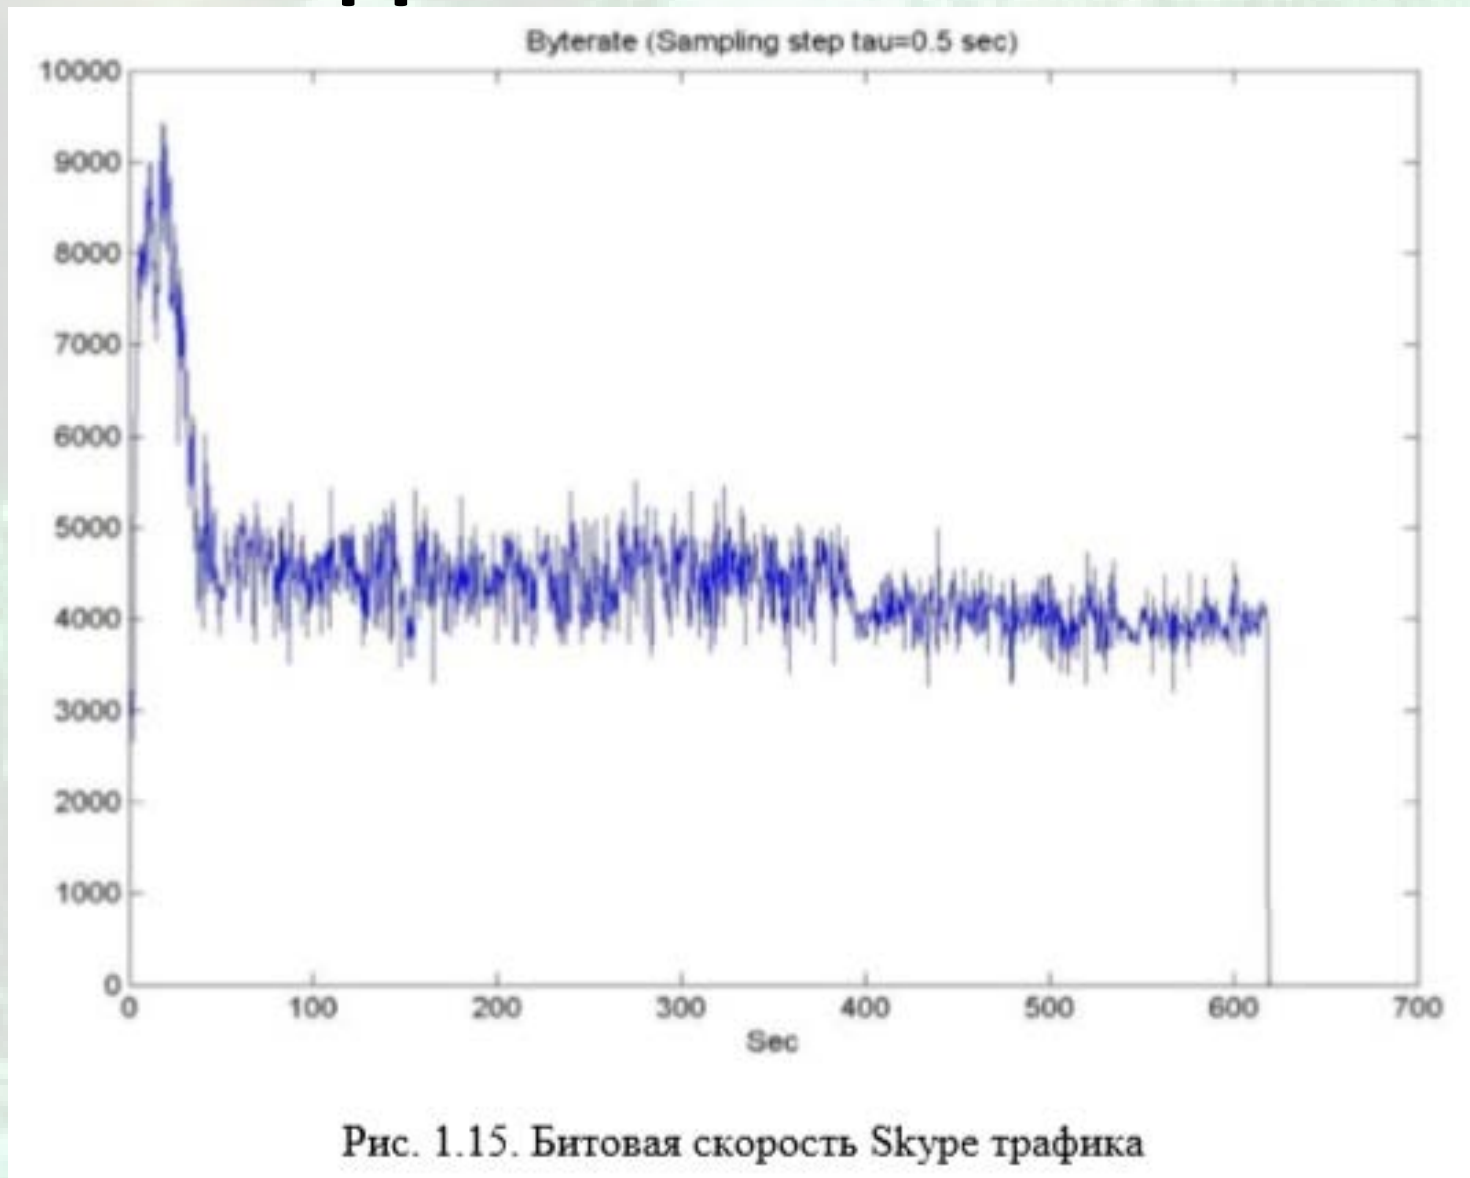
No.	Time	Source	Destination	Protocol	Length	Info
15051	0.000129	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15053	0.000100	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15054	0.000122	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15056	0.000099	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15057	0.000121	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15059	0.000116	91.228.177.209	95.221.91.239	ICMP	1422	[ICMP segment of a reassembled PDU]
15060	0.000107	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15062	0.000098	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15063	0.000136	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15065	0.000122	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15066	0.000094	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15068	0.000136	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15070	0.000708	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15071	0.000097	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15072	0.000079	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15074	0.000143	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15076	0.000159	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15077	0.000140	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15078	0.000049	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]
15080	0.000133	91.228.177.209	95.221.91.239	TCP	1422	[TCP segment of a reassembled PDU]

Поведенческий анализ

Фрагмент видео



Поведенческий анализ




Статистический анализ

Статистический анализ



Статистический анализ

Момент включения видео



Статистический анализ

Фрагмент видео



Статистический анализ (200 пакетов)

весь трафик (подключение к сайту, вкл
видео, просмотр видео)



Статистический анализ (450 пакетов)

весь трафик(подключение к сайту, вкл
видео, просмотр видео)



Эвристический анализ

Идентификация трафика в DPI



Эвристика

Эвристический алгоритм — это алгоритм решения задачи, правильность которого для всех возможных случаев не доказана, но про который известно, что он даёт достаточно хорошее решение в большинстве случаев.

Эвристический анализ - это технология обнаружения по признакам (без гарантированной точности). Используется, когда невозможно определить трафик с помощью сигнатурного анализа, то есть с помощью поиска и сравнения по базе сигнатур. Объектам, обнаруженным с помощью эвристического анализа, присваивается вероятность соответствия, к примеру - 85%.

Совместное использование с другими методами анализа позволяет увеличить точность общей идентификации трафика.

DPI средства управления трафиком

Суммарное использование различных методов анализа позволяет значительно увеличить точность идентификации трафика

DPI
Анализ



Явно
заданные
правила

Сигнатуры

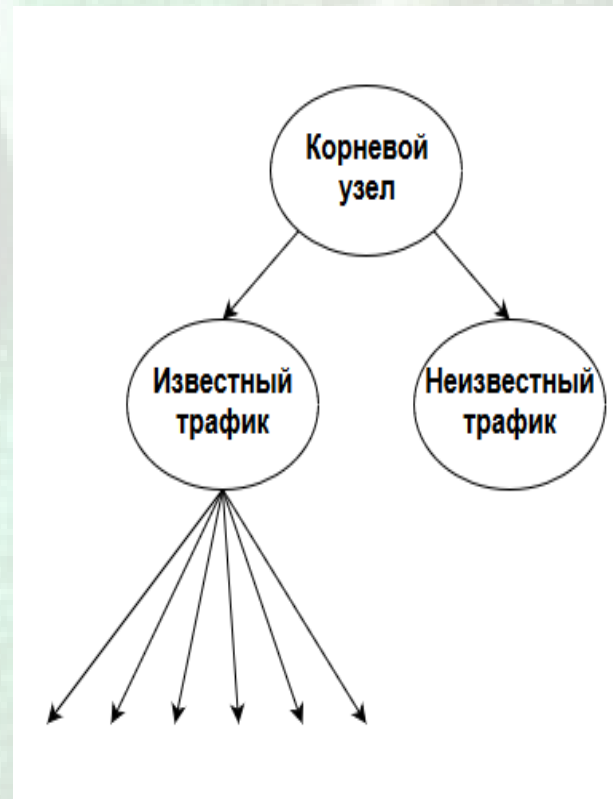

Эвристика

Анализ
поведения

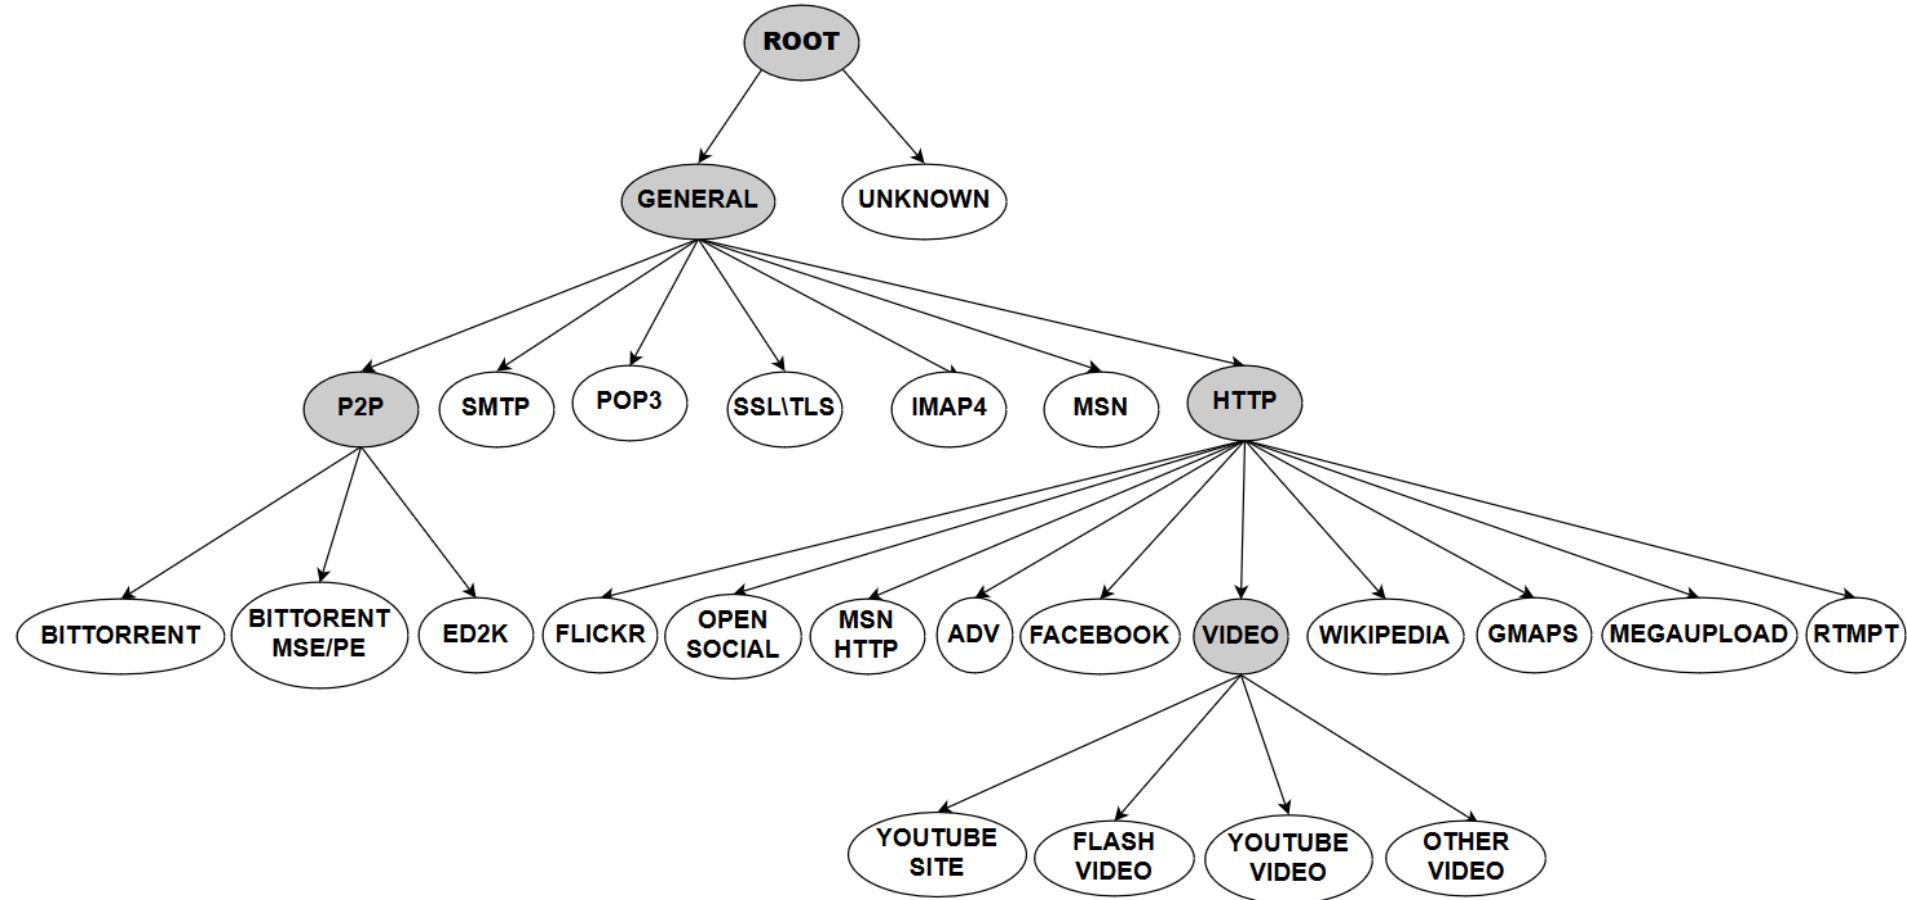
Классификация трафика

Комбинаторы и иерархический анализ

- Комбинаторы увеличивают точность классификации
- Иерархические системы улучшают эффективность и точность классификации



Комбинаторы и иерархический анализ



Комбинаторы

Существуют следующие виды алгоритмов комбинирования:

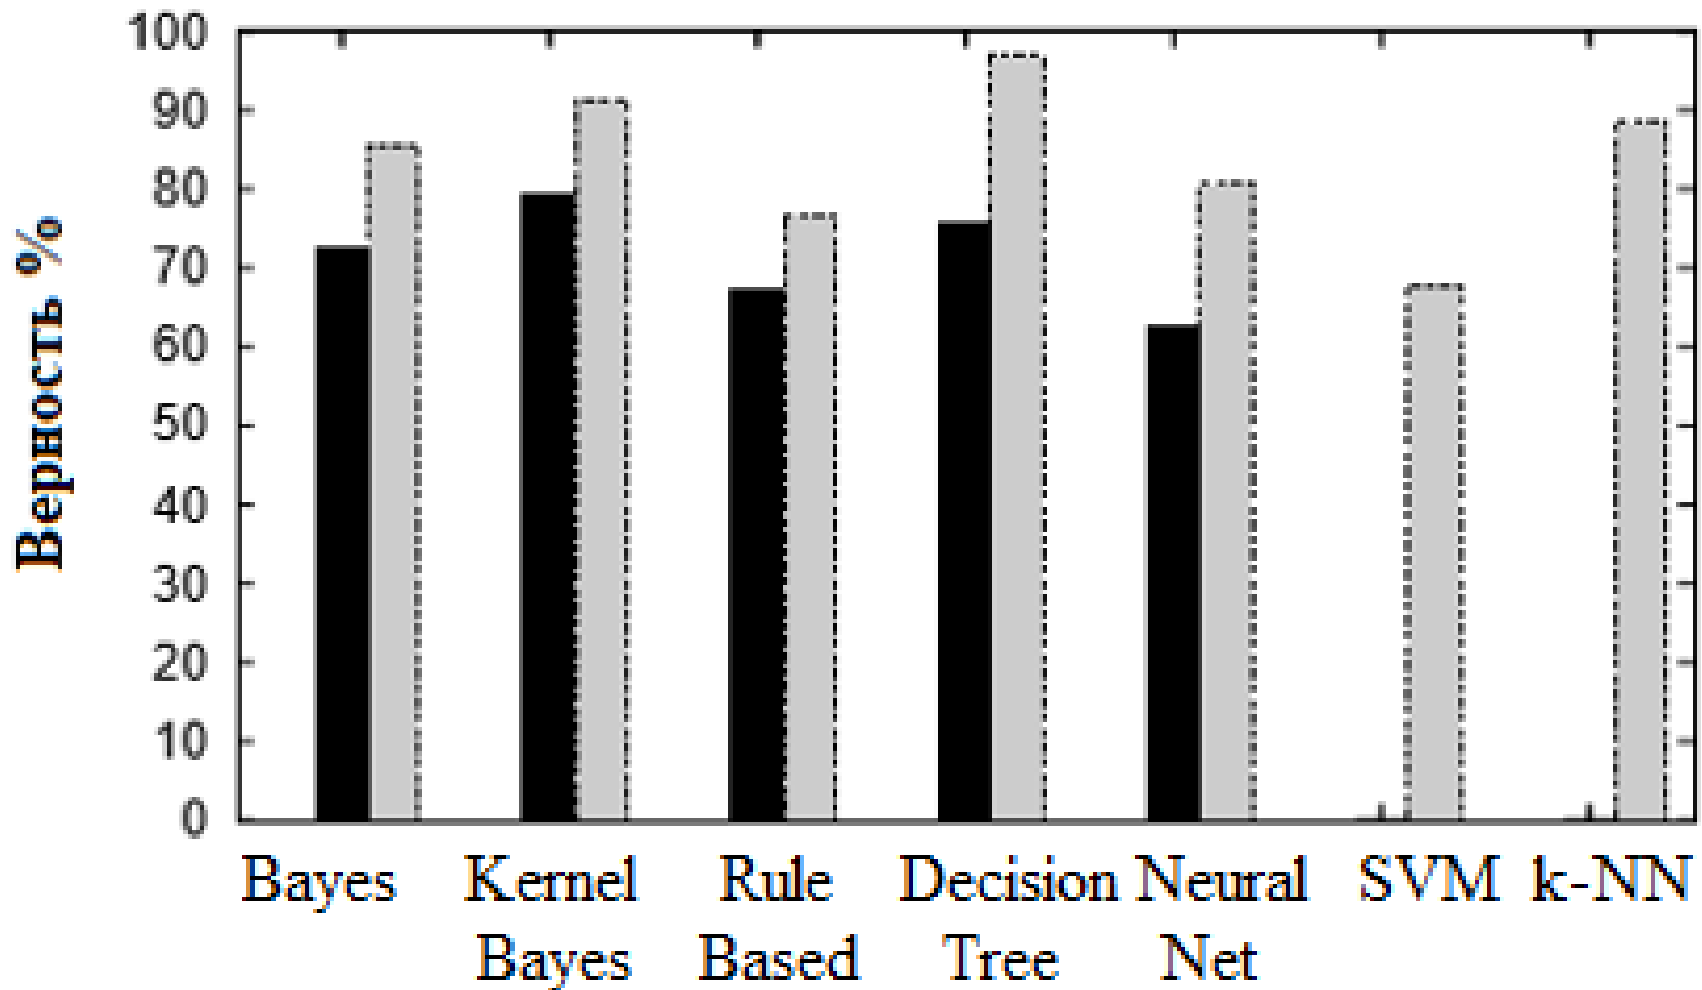
- **Majority Voting (Голосование по большинству),**
- **Weighted Majority Voting (Взвешенное голосование большинства),**
- **Naive Bayes,**
- **Dempster-Shafer combiner,**
- **Behavior-Knowledge Space (BKS) method,**
- **Wernecke's method,**
- **Oracle.**

Анализ применения комбинаторов

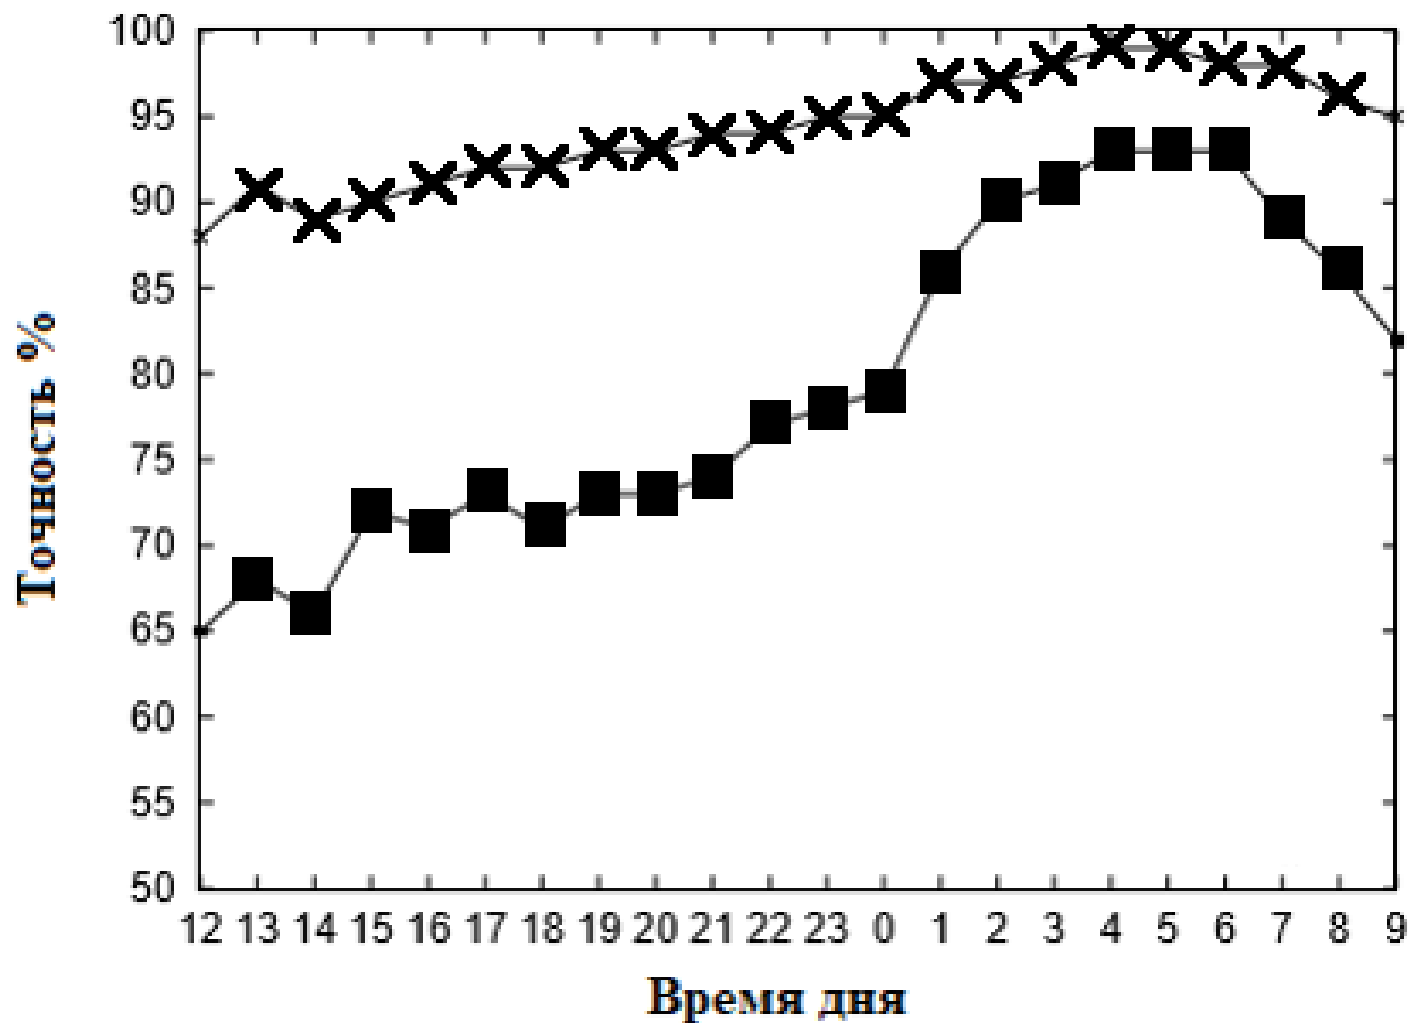
	Количество пакетов									
Классификатор	1	2	3	4	5	6	7	8	9	10
J48	62.1	94.6	95.9	96	96.8	97.1	97.2	97.2	97.2	97.2
K-NN	62.4	91.5	92.8	95	94.9	94.9	95.4	95.7	95.6	95.9
R-TR	72.7	93.4	93.6	94.9	95.3	96.8	96	96	96.1	96.2
RIP	69.5	93.7	94.7	96.2	96.1	96.5	96.7	96.9	96.9	96.9
MLP	43.5	71.7	81	82.3	82.3	82.3	82.3	82.3	82.3	82.3
NBAY	31.5	39.9	42.6	43.7	43.7	43.7	43.7	43.7	43.7	43.7
PL	76.2	83.7	83.7	83.7	83.7	83.7	83.7	83.7	83.7	83.7
PORT	15.6	15.6	15.6	15.6	15.6	15.6	15.6	15.6	15.6	15.6

	Количество пакетов									
Комбинатор	1	2	3	4	5	6	7	8	9	10
MV	57.8	93.9	94.4	95.6	95.9	96.2	96.3	96.3	96.4	96.4
D-S	83.1	96	96.9	97	97.4	97.4	96.4	96.5	96.5	96.5
BKS	97	98.4	98.3	98.4	98.4	98.4	98.4	98.4	98.4	98.4
WER	97	98.3	98.2	98.4	98.4	98.4	98.4	98.4	98.4	98.4

Анализ применения иерархического классификатора
черный – обычный классификатор
серый – иерархический классификатор



Анализ применения иерархического классификатора



—x— иерархический классификатор

—■— обычный классификатор

DataMining анализ

DataMining

- это процесс выделения из анализируемых данных **неструктурированной информации и метаданных**

и представления ее в виде, возможном для дальнейшего анализа и использования.

Основа **шаблоны - закономерности**, свойственные анализируемым данным, которые могут быть выражены в понятной человеку форме.

Цель поиска закономерностей - представление данных в виде, отображающем искомые процессы, а также построение моделей прогнозирования

DataMining

-использует аналитические методы,
большинство из которых было разработано в рамках
теории **искусственного интеллекта**.

Непосредственное использование данных

Или выявление шаблонов-закономерностей

Непосредственное использование данных или сохранение данных.

При использовании данного метода исходные данные хранятся в явном детализированном виде и непосредственно используются на стадиях прогностического моделирования и/или анализа исключения.

Недостатком данного метода является возникновение трудностей при использовании больших баз данных.

Методы этой группы: кластерный анализ, метод ближайшего соседа, метод k-ближайшего соседа, рассуждение по аналогии.

Непосредственное использование данных или сохранение данных.

Методы этой группы:

- **кластерный анализ,**
- **метод ближайшего соседа,**
- **метод k-ближайшего соседа,**
- **рассуждение по аналогии.**

Выявление и использование формализованных закономерностей или дистилляция шаблонов.

В рамках данной технологии на стадии свободного поиска из исходных данных **извлекается один образец** (шаблон) и преобразуется в некие **формальные конструкции**, что является отличительной чертой данного метода.

Результаты стадии свободного поиска значительно компактнее самих баз данных, и они используются далее в прогностическом моделировании и анализе исключений .

Методы этой группы: логические методы; методы визуализации; методы кросс-табуляции; методы, основанные на уравнениях.

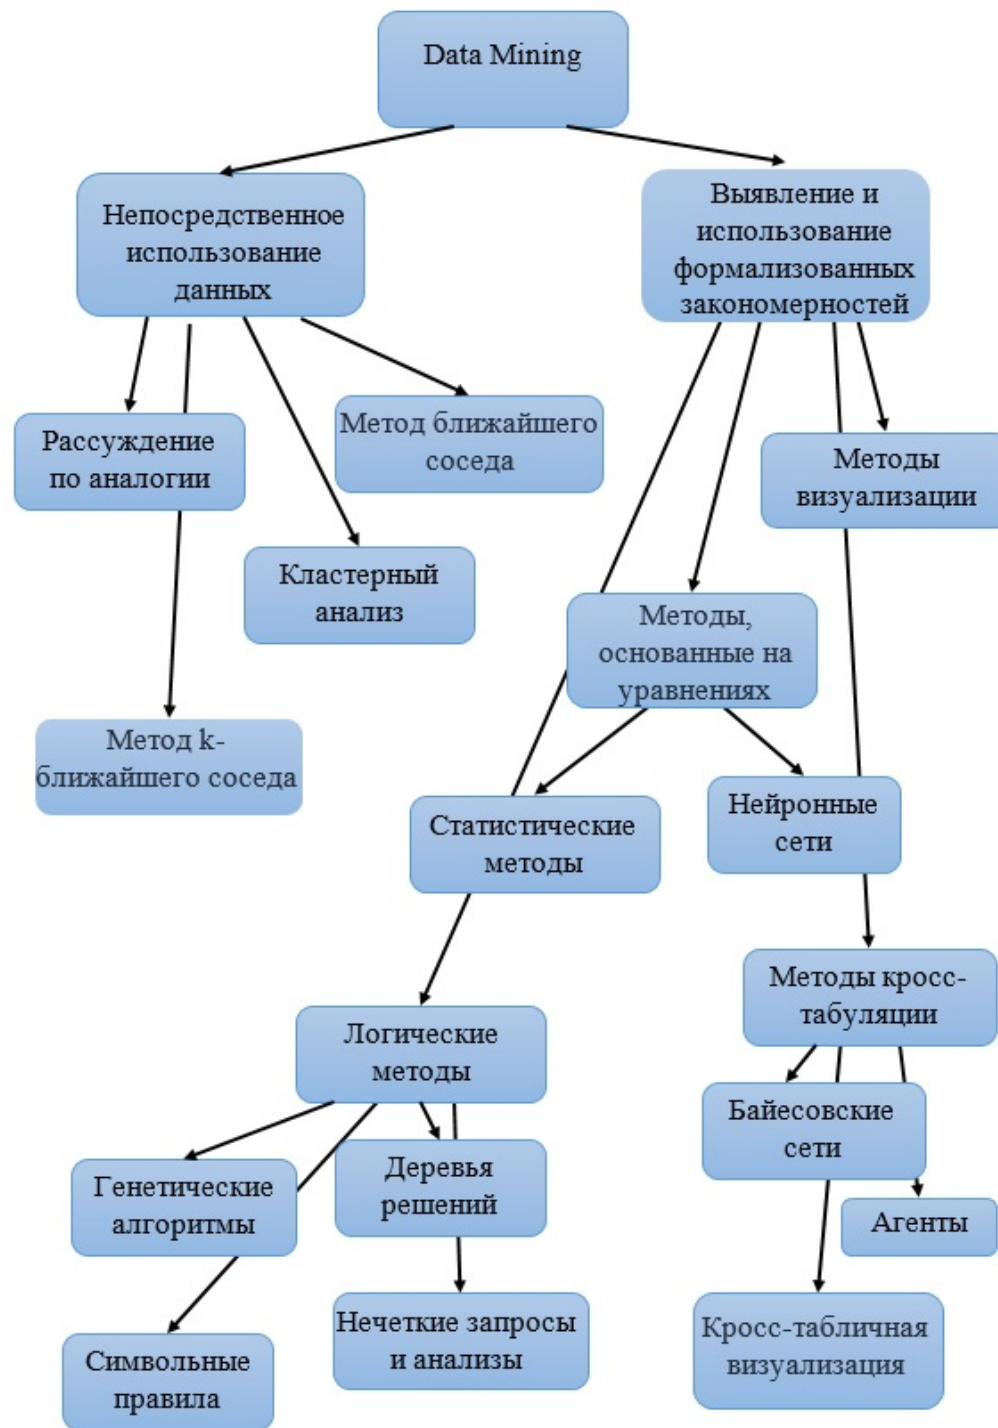
Выявление и использование формализованных закономерностей или дистилляция шаблонов.

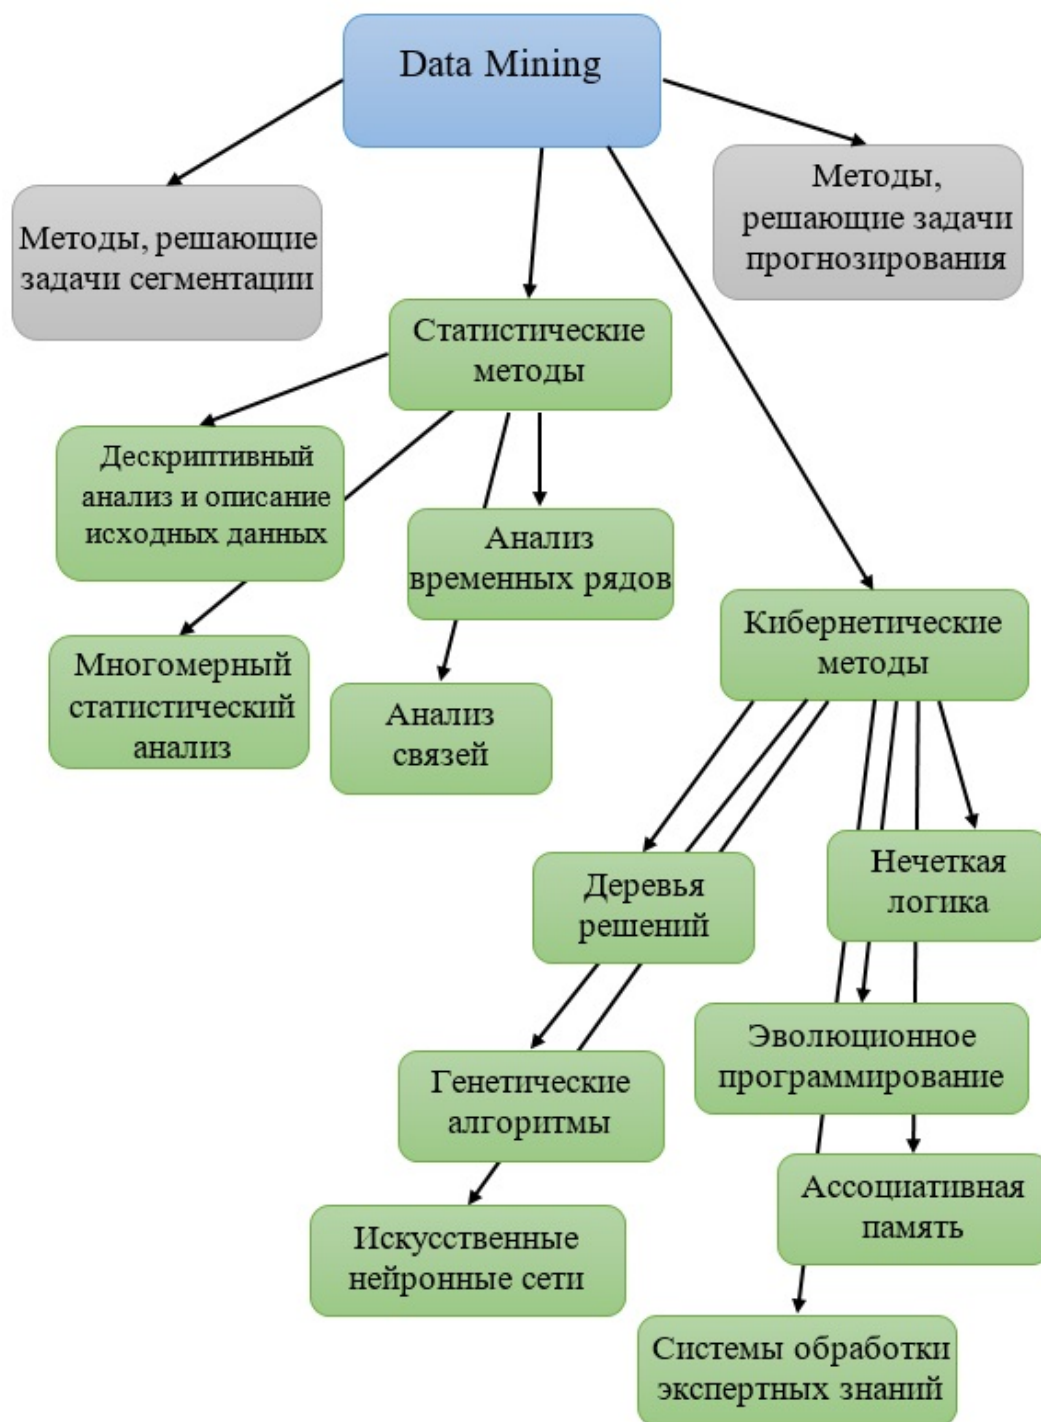
Методы этой группы:

- **логические методы;**
- **методы визуализации;**
- **методы кросс-табуляции;**
- **методы, основанные на уравнениях.**

Методы DataMining

- Корреляционный, регрессионный и другие виды статистического анализа.
- Нечеткая логика
- Генетические алгоритмы
- Нейронные сети
- Кластеризация





Логические методы

- **включают нечеткие запросы и анализы;**
- **символьные правила;**
- **деревья решений ;**
- **генетические алгоритмы.**

Методы данной группы являются наиболее интерпретируемыми:

они оформляют найденные закономерности, в большинстве случаев, в достаточно прозрачном виде с точки зрения пользователя.

Полученные правила могут включать непрерывные и дискретные переменные.

Методы кросс-табуляции:

- агенты,
- байесовские (доверительные) сети,
- кросс-табличная визуализация.

При классификации с использованием **naive Bayes**

после проведенного машинного обучения на основе заранее известных потоков,

неизвестные потоки трафика соотносятся с выбранными категориями.

Например,

- www, email, bulk (большие объемы, ftp),
- serv (сервисы, протоколы X11, dns, ident, ldap, ntp),
- db (протоколы postgres, sqlnet oracle, ingres),
- p2p (KaZaA, BitTorrent, GnuTella),
- att (атаки, вирусы и черви),
- mmedia (мультимедиа, wmp, Real).

Методы на основе уравнений

Методы данной группы выражают выявленные закономерности в виде уравнений .

Следовательно, они могут работать лишь с численными переменными, а другие типы переменных должны быть подвергнуты кодированию.

Это является ограничением применения методов данной группы, но несмотря на это, они широко используются при решении задач прогнозирования.

Основные методы данной группы:

- **статистические методы**
- **нейронные сети**

Статистические методы наиболее часто применяются для решения задач прогнозирования.

- **корреляционно-регрессионный анализ,**
- **корреляция рядов динамики,**
- **выявление тенденций динамических рядов,**
- **гармонический анализ.**

Также существует другой способ классификации методов DataMining

на статистические и кибернетические методы.

Этот способ разделения основан на различных подходах к обучению математических моделей.

Статистические методы основаны на использовании **усредненного накопленного опыта**, который отражен в ретроспективных данных.

Статистические методы DataMining включают в себя:

- **дескриптивный анализ и описание исх. данных,**
- **анализ связей,**
- **многомерный статистический анализ**
- **анализ временных рядов.**

Кибернетические методы включают в себя множество разнородных математических подходов.


Кибернетические методы можно разделить на:

- **искусственные нейронные сети,**
- **эволюционное программирование,**
- **генетические алгоритмы,**
- **ассоциативная память,**
- **нечеткая логика,**
- **деревья решений ,**
- **системы обработки экспертных знаний .**

методы DataMining можно классифицировать по поставленным задачам: подразделение на решающие *задачи сегментации* (т.е. задачи классификации и кластеризации) К методам, направленным на получение **описательных результатов**, относятся:

- **алгоритм k-средних,**
- **k-медианы,**
- **иерархические методы кластерного анализа,**
- **самоорганизующиеся карты Кохонена,**
- **методы кросс-табличной визуализации,**
- **различные методы визуализации и другие.**

Кластеризация

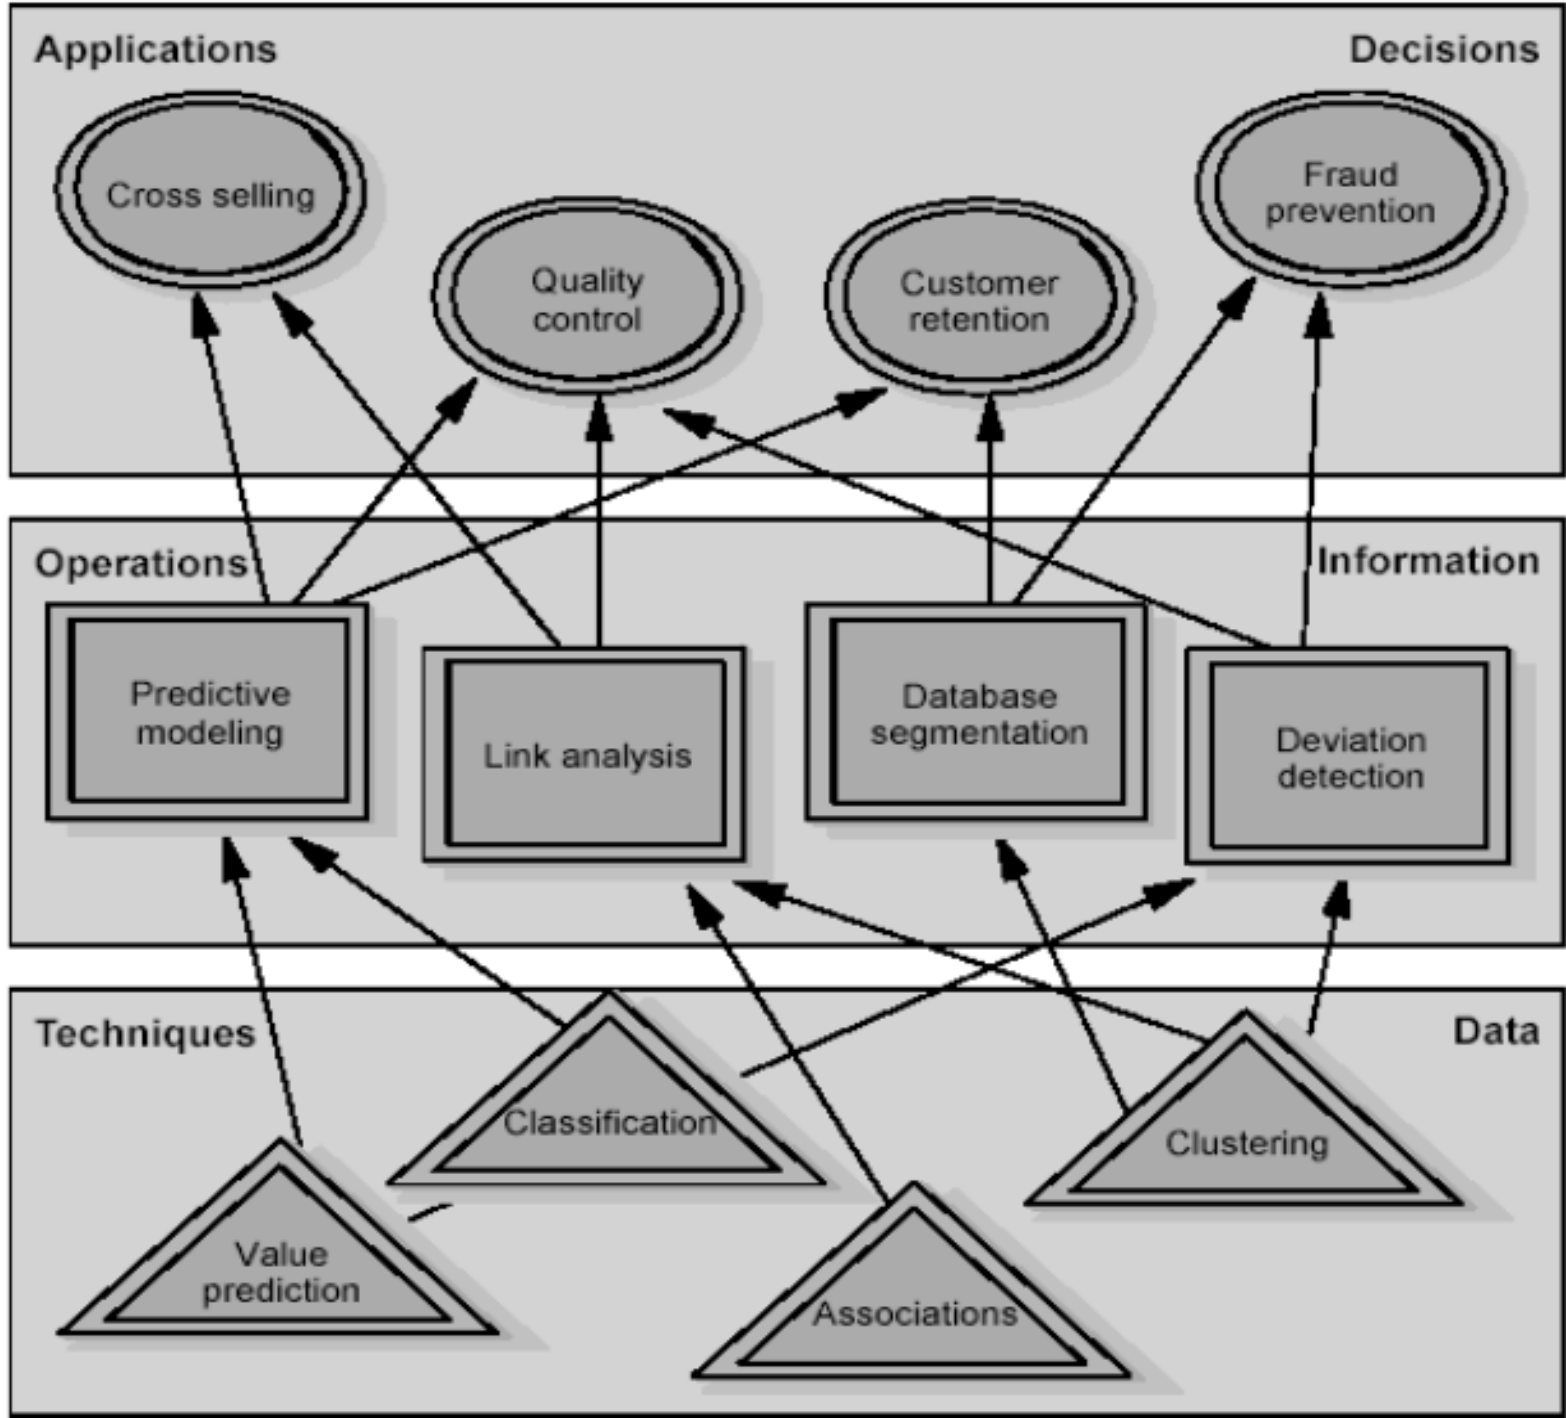


методы DataMining можно классифицировать по поставленным задачам: подразделение на решающие **задачи прогнозирования**.

Прогнозирующие методы используют значения одних переменных для прогнозирования неизвестных (пропущенных) или будущих значений других (целевых) переменных.

К методам, направленным на получение прогнозирующих результатов, относятся такие методы:

- **нейронные сети,**
- **деревья решений ,**
- **линейная регрессия,**
- **метод ближайшего соседа,**
- **метод опорных векторов и другие.**



Спасибо за внимание.

Далее: Архитектура DPI.

Вопросы?

Ст. преп. каф. Инфокоммуникационных систем СПбГУТ,

Фицов Вадим Владленович,

