

# **ЛЕКЦИЯ 12.**

## **Хэш-функции**

**12.1. Требования к хэш-функциям.**

**12.2. Простые хэш-функции.**

**12.3. Парадокс дня рождения и атаки, на нем основанные.**

**12.4. Способы использования хэш-функций.**

**12.5. Криптоанализ хэш-функций.**

**Хэш-функцией** называется **односторонняя** функция, предназначенная для получения *дайджеста* или "отпечатков пальцев" файла, сообщения или некоторого блока данных.

**Хэш-код** создается **функцией H**:

$$h = H(M),$$

где **M** является сообщением *произвольной* длины,  
а **h** является *хэш-кодом* **фиксированной** длины.

Когда хэш-функция зависит от **ключа**, результат ее вычисления носит название **кода аутентификации сообщения (MAC – Message Authentication Code)**.

**Хэш-функция H**, которая используется для **аутентификации сообщений**, должна обладать следующими свойствами:

1. **Хэш-функция H** должна применяться к блоку данных **любой** длины.
2. **Хэш-функция H** создает выход **фиксированной** длины.
3. **H (M)** относительно **легко (за полиномиальное время)** вычисляется для любого значения **M**.
4. Для любого данного значения *хэш-кода* **h** **вычислительно невозможно** найти **M** такое, что **H (M) = h**.
5. Для любого данного **x** **вычислительно невозможно** найти такое **y**  $\neq x$ , что

$$H(y) = H(x).$$

Такое свойство называют **слабой сопротивляемостью коллизиям**.

**Коллизией** называется совпадение дайджестов для различных данных.

6. **Вычислительно невозможно** найти произвольную пару **(x, y)** такую, что

$$H(y) = H(x).$$

Это свойство называют **сильной сопротивляемостью коллизиям**.

Первые три свойства требуют, чтобы хэш-функция создавала хэш-код для любого сообщения.

Четвертое свойство определяет требование **односторонности** хэш-функции: **легко создать** хэш-код по данному сообщению, но **невозможно восстановить** сообщение по данному хэш-коду.

Пятое свойство гарантирует то, что не удастся найти другое сообщение, дающее в результате хэширования **то же самое значение**, что и данное сообщение.

*Если это свойство не выполнено, противник может действовать по следующей схеме:*

- перехватить сообщение вместе с присоединенным к нему **шифрованным** хэш-кодом,
- вычислить *нешифрованный* хэш-код сообщения,
- создать **альтернативное** сообщение с **тем же хэш-кодом**.

Шестое свойство определяет **стойкость** функции хэширования к конкретному классу

**атак, построенных на парадоксе «задачи о днях рождения».**

Все функции хэширования построены на следующих **общих** принципах.

1. Вводимое значение (сообщение, файл и т.д.) рассматривается как

**последовательность  $n$ -битовых блоков.**

2. Вводимые данные обрабатываются

**последовательно блок за блоком,**

чтобы в результате получить

**$n$ -битовое значение функции хэширования.**

**Простейшая** функция хэширования - связывание всех блоков операцией *поразрядного* **исключающего "ИЛИ" (XOR)**:  $C_i = b_{i1} \oplus b_{i2} \oplus \dots \oplus b_{im}$ ,

где

- $C_i$  –  $i$ -й бит хэш-кода,  $1 \leq i \leq n$ ,
- $m$  – число  $n$ -битовых блоков ввода,
- $b_{ij}$  –  $i$ -й бит в  $j$ -м блоке,
- $\oplus$  - операция **XOR**.

Эта процедура осуществляет *простой побитовый контроль четности* и называется **продольным контролем чётности**.

### Простая функция хэширования, выполняющая операцию XOR

	Бит 1	Бит 2	...	Бит n
Блок 1	$b_{11}$	$b_{21}$	...	$b_{n1}$
Блок 2	$b_{12}$	$b_{22}$	...	$b_{n2}$
...	...	...	...	...
Блок m	$b_{1m}$	$b_{2m}$	...	$b_{nm}$
Хэш-код	$C_1$	$C_2$	...	$C_n$


Возможно усовершенствовать такую схему выполнением *однобитового циклического сдвига* или *поворота* значения функции хэширования после завершения обработки каждого очередного блока.

Эта процедура состоит из следующих этапов:

1. **Начальная инициализация**  $n$ -битового значения функции хэширования **нулевым** значением.
2. **Последовательная обработка  $n$ -битовых блоков данных** по следующему правилу.

- \*Выполнение **циклического сдвига** текущего значения функции хэширования влево на один бит.
- \***Добавление** текущего блока к значению функции хэширования с помощью операции **XOR**.

Эта процедура демонстрирует эффект "**рандомизации**" вводимых данных и разрушения регулярностей, которые наблюдаются для вводимых данных.



## Две простые функции хэширования

Когда шифруются и *хэш-код*, и *сообщение* требуется шифрование всего сообщения в **режиме сцепления блоков (CBC)**:

1. Имея сообщение из последовательности *64-битовых* блоков  $X_1, X_2, \dots, X_n$ , сначала следует вычислить *хэш-код*  $C$ , равный результату связывания всех блоков с помощью операции **XOR**,

$$C = X_1 \oplus X_2 \oplus \dots \oplus X_n,$$

2. а затем присоединить полученный *хэш-код*  $C$  к концу сообщения в качестве еще одного блока:

$$C = X_{n+1}.$$

3. После этого все сообщение вместе с присоединенным *хэш-кодом*  $C$  шифруется в режиме **CBC**, в результате чего получается шифрованное сообщение

$$Y_1, Y_2, \dots, Y_{n+1}.$$

## Метод сцепления блоков

(техника сцепления шифрованных блоков, но без использования секретного ключа).

1. Сообщение  $M$  делится на блоки фиксированной длины  $M_1, M_2, \dots, M_n$
2. и используется любая система традиционного шифрования (например,  $DES$ ), чтобы вычислить хэш-код  $G$  следующим образом:

$$\begin{aligned} H_0 &= \text{начальное значение,} \\ H_i &= E_{M_i} [ H_{i-1} ], \\ G &= H_n . \end{aligned}$$

### Парадокс дня рождения ПОСТАНОВКА ЗАДАЧИ (Ч.1)

Предположим, количество выходных значений хэш-функции  $H$  равно  $n$ .

Каким должно быть число  $k$ , чтобы для конкретного значения  $X$  и значений  $Y_1, \dots, Y_k$  вероятность того, что хотя бы для одного  $Y_i$  выполнялось равенство

$$H(X) = H(Y),$$

была бы *больше 0,5?*

### РЕШЕНИЕ

1. Для одного  $Y$  вероятность того, что  $H(X) = H(Y)$ , равна  $1/n$ .
2. Соответственно, вероятность того, что  $H(X) \neq H(Y)$ , равна  $1 - 1/n$ .
3. Если создать  $k$  значений, то вероятность того, что ни для одного из них не будет совпадений, равна произведению вероятностей, соответствующих одному значению, т.е.

$$(1 - 1/n)^k.$$

Следовательно, вероятность, по крайней мере, одного совпадения равна

$$1 - (1 - 1/n)^k.$$

По формуле бинома Ньютона

$$(1 - a)^k = 1 - ka + (k(k-1)/2!)a^2 - \dots \approx 1 - ka.$$

Т.е.

$$1 - (1 - k/n) = k/n = 0,5,$$

откуда

$$k = n/2.$$

Для  $m$ -битового хэш-кода достаточно выбрать  $2^{m-1}$  сообщений, чтобы вероятность совпадения хэш-кодов была больше **0,5**.

## ПОСТАНОВКА ЗАДАЧИ (Ч.2)

Обозначим  $P(n, k)$  вероятность того, что во множестве из  $k$  элементов, каждый из которых может принимать  $n$  значений, есть хотя бы два с одинаковыми значениями.

Чему должно быть равно  $k$ , чтобы  $P(n, k)$  была бы больше **0,5**?

### РЕШЕНИЕ

Число различных способов выбора элементов таким образом, чтобы при этом не было дублей, равно

$$n(n-1) \dots (n-k+1)n!/(n-k)!.$$

Всего число возможных способов выбора элементов равно

$$n^k.$$

Вероятность того, что дублей нет, равна

$$n!/(n-k)!n^k.$$

Вероятность того, что есть дубли, соответственно равна:

$$1 - n!/(n-k)!n^k.$$

$$P(n, k) = 1 - n! / ((n-k)! \times n^k) =$$

$$1 - (n \times (n-1) \times \dots \times (n-k+1)) / n^k =$$

$$1 - [(n-1)/n \times (n-2)/n \times \dots \times (n-k+1)/n] =$$

$$1 - [(1-1/n) \times (1-2/n) \times \dots \times (1-(k-1)/n)].$$

Известно, что  $1 - x \leq e^{-x}$ .

По условию задачи

$$P(n, k) > 1 - [e^{-1/n} \times e^{-2/n} \times \dots \times e^{-k/n}], \quad \text{т.е.}$$

$$P(n, k) > 1 - e^{-k(k-1)/n}.$$

Следовательно,

$$1/2 = 1 - e^{-k(k-1)/n}, \quad \text{и}$$

$$2 = e^{k(k-1)/n}.$$

Отсюда

$$\ln 2 = k(k-1) / 2n \quad \text{и}$$

$$k(k-1) \approx k^2.$$

Окончательно имеем

$$k = (2n \times \ln 2)^{1/2} = 1,17 n^{1/2} \approx n^{1/2}.$$

Таким образом, если *хэш-код* имеет длину  $m$  бит, т.е. принимает  $2^m$  значений, то

$$k = \sqrt{2^m} = 2^{m/2}.$$

**"Парадокс дня рождения"** - для того, чтобы вероятность совпадения дней рождения у двух человек была больше **0,5**, в группе должно быть всего **23** человека.

Возможна следующая стратегия:

1. **Противник (атакующий)** создает  $2^{m/2}$  вариантов сообщения, каждое из которых имеет некоторый определенный смысл.

Противник подготавливает **такое же** количество сообщений, каждое из которых является **поддельным** и предназначено для замены настоящего сообщения.

Два набора сообщений сравниваются в поисках пары сообщений, имеющих **одинаковый хэш-код**. Вероятность успеха в соответствии с "парадоксом дня рождения" больше, чем **0,5**.

Если соответствующая пара не найдена, то создаются дополнительные исходные и поддельные сообщения **до тех пор, пока не будет найдена пара**.

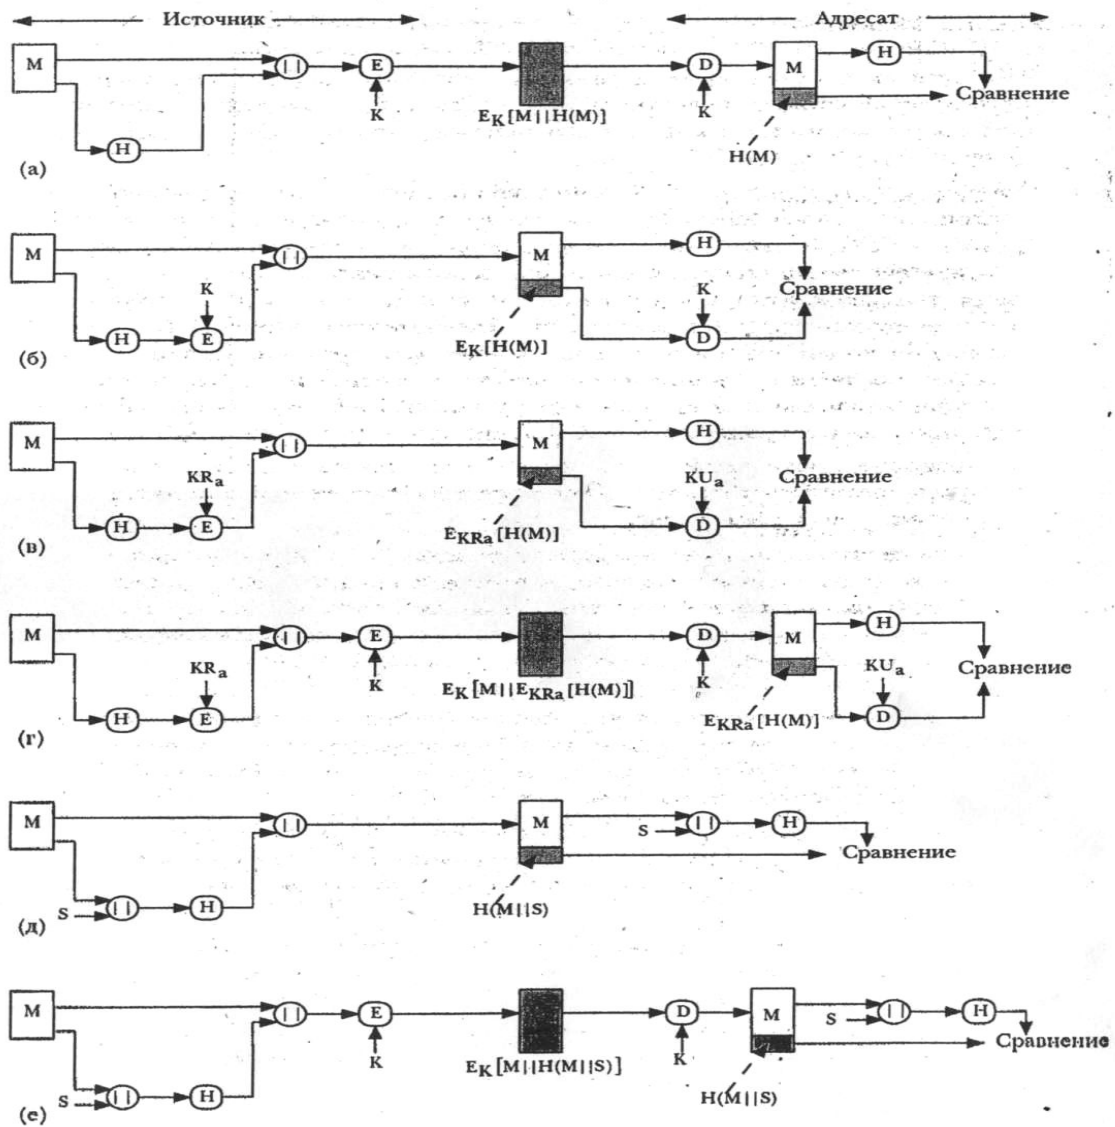
2. Атакующий предлагает **отправителю** исходный вариант сообщения для подписи.

Эта подпись может быть затем присоединена к поддельному варианту для передачи получателю. Так как оба варианта имеют **один и тот же хэш-код**, будет создана **одинаковая** подпись.

**Противник будет уверен в успехе, даже не зная ключа шифрования.**

Если используется **64-битный хэш-код**, то необходимая сложность вычислений





**Основные способы использования функции хэширования**


## Основные возможности использования функции хэширования

<p>(а) <math>A \rightarrow B: E_K [ M \parallel H(M) ]</math></p> <ul style="list-style-type: none"> <li>• Обеспечивает <u>конфиденциальность</u></li> <li>- Только стороны <b>A</b> и <b>B</b> знают <b>K</b></li> <li>• Обеспечивает <u>аутентификацию</u></li> <li>- <b>H(M)</b> криптографически защищено</li> </ul>	<p>(г) <math>A \rightarrow B: E_K [ M \parallel E_{KR_A} [ H(M) ] ]</math></p> <ul style="list-style-type: none"> <li>• Обеспечивает <u>аутентификацию</u> и <u>цифровую подпись</u></li> <li>• Обеспечивает <u>конфиденциальность</u></li> <li>- Только стороны <b>A</b> и <b>B</b> знают <b>K</b></li> </ul>
<p>(б) <math>A \rightarrow B: M \parallel E_K [ H(M) ]</math></p> <ul style="list-style-type: none"> <li>• Обеспечивает <u>аутентификацию</u></li> <li>- <b>H(M)</b> криптографически защищено</li> </ul>	<p>(д) <math>A \rightarrow B: M \parallel H(M \parallel S)</math></p> <ul style="list-style-type: none"> <li>• Обеспечивает <u>аутентификацию</u></li> <li>- Только стороны <b>A</b> и <b>B</b> знают <b>S</b></li> </ul>
<p>(в) <math>A \rightarrow B: M \parallel E_{KR_A} [ H(M) ]</math></p> <ul style="list-style-type: none"> <li>• Обеспечивает <u>аутентификацию</u> и <u>цифровую подпись</u></li> <li>- <b>H(M)</b> криптографически защищено</li> <li>- Только сторона <b>A</b> может создать <math>E_{KR_A} [ H(M) ]</math></li> </ul>	<p>(е) <math>A \rightarrow B: E_K [ M \parallel H(M \parallel S) ]</math></p> <ul style="list-style-type: none"> <li>• Обеспечивает <u>аутентификацию</u></li> <li>- Только стороны <b>A</b> и <b>B</b> знают <b>S</b></li> <li>• Обеспечивает <u>конфиденциальность</u></li> <li>- Только стороны <b>A</b> и <b>B</b> знают <b>K</b></li> </ul>

### Причины интереса к методам, позволяющим избежать шифрования:

- Программное обеспечение, выполняющее шифрование, работает довольно **медленно**.
- Цены на аппаратные средства шифрования довольно **высокие**.
- Аппаратные средства шифрования оптимизируются для работы с большими объемами данных.  
При малых блоках данных значительная часть времени тратится непроизводительно на инициализацию/вызов.
- Алгоритмы шифрования могут быть защищены патентами, что тоже выливается в дополнительные **расходы**.
- Алгоритмы шифрования являются одним из вопросов **экспортного государственного регулирования**.

## Криптоанализ хэш-функций.



Общая структура защищенного хэш-кода  
(итерированной функцией хэширования)

На рис. использованы обозначения:

- $IV$  – начальное значение,
- $CV$  – переменная сцепления,
- $Y_i$  –  $i$ -й вводимый блок,
- $f$  – алгоритм сжатия,
- $L$  – число вводимых блоков,
- $n$  – длина хэш-кода,
- $b$  – длина вводимого блока.

**Функция хэширования** может быть описана следующим образом:

$CV_0 = IV =$  начальное  $n$ -битовое значение,

$$CV_i = f(CV_{i-1}, Y_{i-1}), \quad 1 \leq i \leq L,$$

$$H(M) = CV_L,$$

где вводимыми данными функции хэширования является сообщение  $M$ , складывающееся из блоков  $Y_0, Y_1, \dots, Y_L$

Если **функция сжатия** обладает **сопротивляемостью коллизиям**, то такой же будет и **итерированная функция хэширования**.

Противник должен найти:

1. либо два сообщения **равной** длины, имеющие **одинаковые** значения **функции хэширования**,
2. либо два сообщения **разной** длины, которые вместе с соответствующими им значениями длины будут иметь **одинаковые** значения **функции хэширования**.

Проблема создания защищенной функции хэширования сводится к

проблеме поиска **функции сжатия**,

обладающей **сопротивляемостью коллизиям** и работающей с вводимыми данными некоторой фиксированной длины.

**Криптоанализ** функций хэширования обычно сосредоточен на исследовании

*внутренней структуры  $f$*

и опирается на попытки найти эффективные

методы обнаружения коллизий при

*однократном выполнении  $f$ .*

Следует при этом иметь в виду, что коллизии должны существовать в *любой* функции хэширования, поскольку последняя отображает как минимум

*блок длины  $b$  в хэш-код длины  $n$ , где  $b > n$ .*

Требуется лишь **вычислительная невозможность** обнаружить такие коллизии.