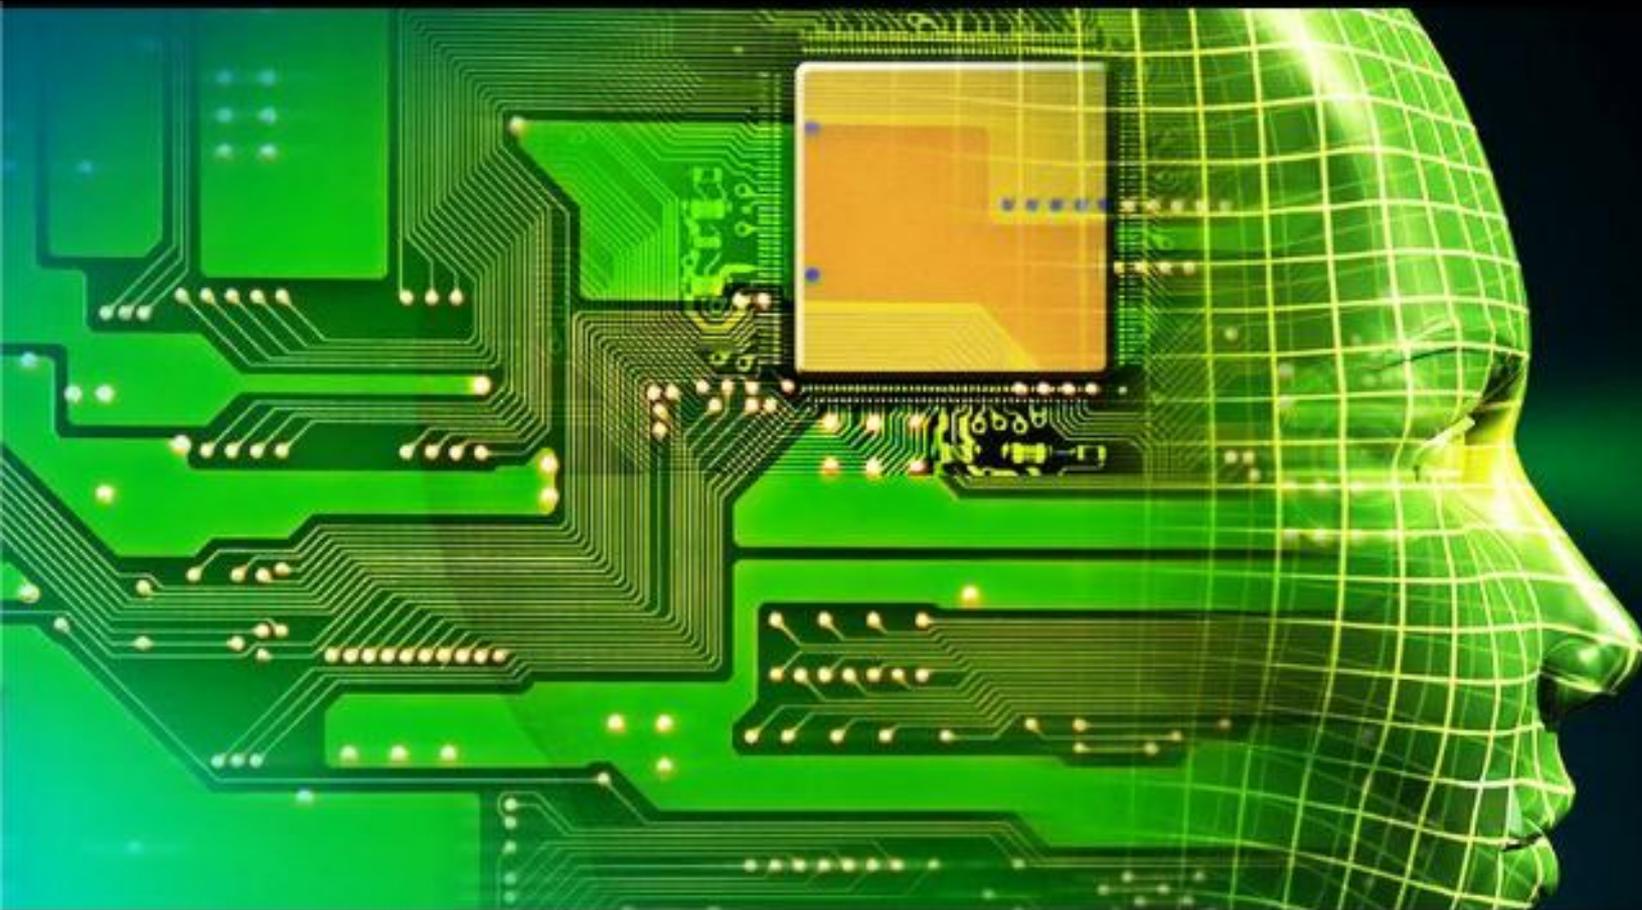


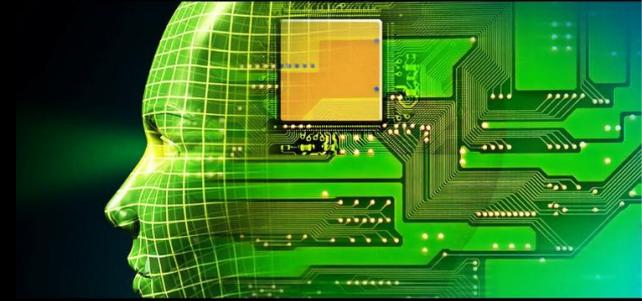
# Искусственный интеллект: современный подход



Знания и рассуждения в условиях  
неопределённости



# Логический подход



$\forall p \text{ Симптом}(p, \text{зубная боль}) \Rightarrow \text{Болезнь}(p, \text{дупло})$

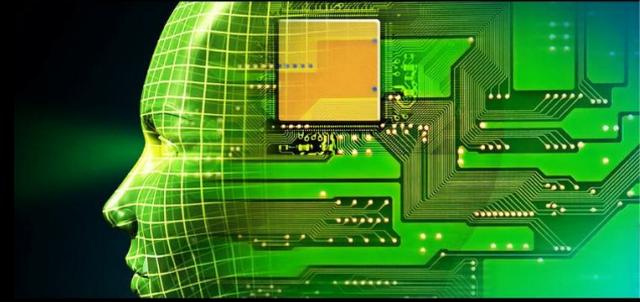
$\forall p \text{ Симптом}(p, \text{зубная боль}) \Rightarrow$

$\text{Болезнь}(p, \text{дупло}) \vee \text{Болезнь}(p, \text{десна}) \vee \text{Болезнь}(p, \text{нарыв}) \vee \dots$

$\forall p \text{ Болезнь}(p, \text{дупло}) \Rightarrow \text{Симптом}(p, \text{зубная боль})$



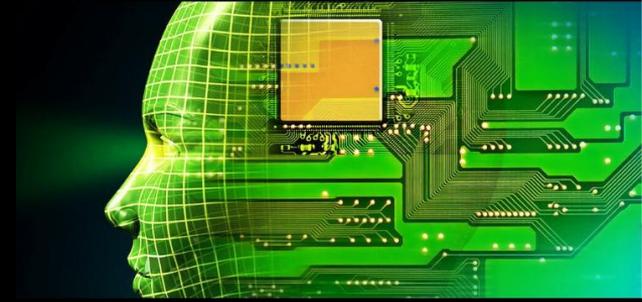
# Причины неудачи



Лень



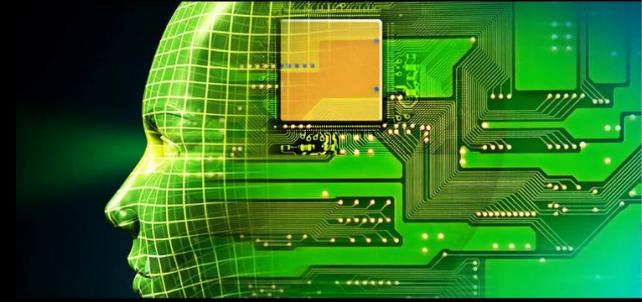
# Причины неудачи



Теоретическое невежество



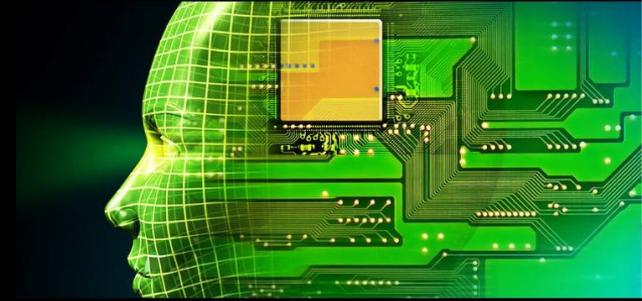
# Причины неудачи



Практическое невежество



Итог

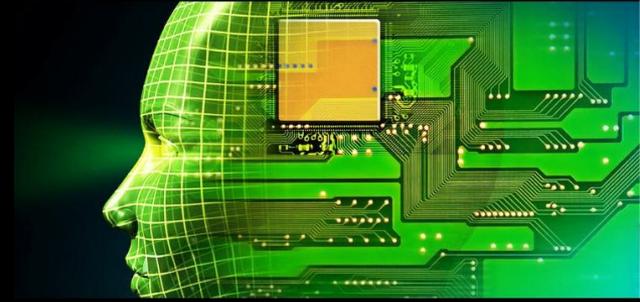


# степень 0 1 уверенности

Стандартный аппарат: **теория вероятностей**  
(*суммарный учёт неопределённости,  
возникающей из-за лени и невежества*)



# Базовые понятия теории вероятностей

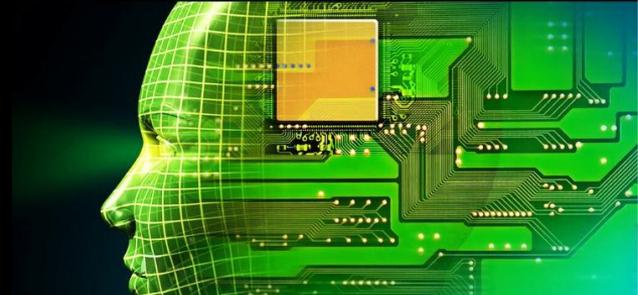


Я предполагаю, что вы знаете, помните и любите следующие понятия:

- Вероятность
- Независимость событий
- Условная вероятность
- Случайная величина
- Распределение случайной величины
- Правило Байеса



# Пример вероятностного вывода



	<i>toothache</i>		$\neg$ <i>toothache</i>	
	<i>catch</i>	$\neg$ <i>catch</i>	<i>catch</i>	$\neg$ <i>catch</i>
<i>cavity</i>	0.108	0.012	0.072	0.008
$\neg$ <i>cavity</i>	0.016	0.064	0.144	0.576

$$P(\text{cavity} | \text{toothache}) = \frac{P(\text{cavity} \wedge \text{toothache})}{P(\text{toothache})}$$

$$= \frac{0.108 + 0.012}{0.108 + 0.012 + 0.016 + 0.064}$$

$$P(\text{Cavity} | \text{toothache}) = \alpha \{P(\text{Cavity}, \text{toothache})\}$$

$$= \alpha [P(\text{Cavity}, \text{toothache}, \text{catch}) + P(\text{Cavity}, \text{toothache}, \neg \text{catch})]$$

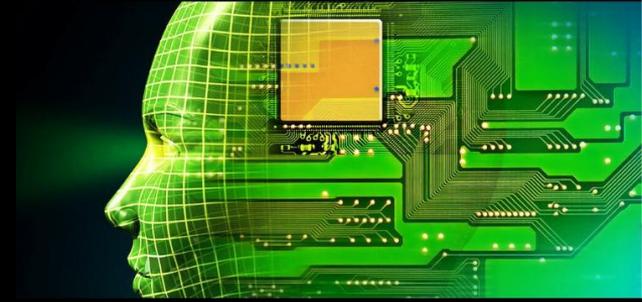
$$= \alpha [0.108, 0.016 + 0.012, 0.064] = \alpha [0.12, 0.08] = [0.6, 0.4]$$

$$P(\neg \text{cavity} | \text{toothache}) = \frac{P(\neg \text{cavity} \wedge \text{toothache})}{P(\text{toothache})}$$

$$= \frac{0.016 + 0.064}{0.108 + 0.012 + 0.016 + 0.064} = 0.4$$



# Вероятностный вывод



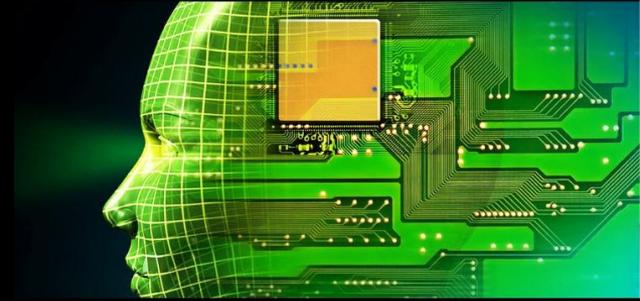
Обозначения:

- query variables  $X_i$
- evidence variables  $E_1, E_2, \dots, E_m$
- Nonevidence (hidden) variables  $Y_1, Y_2, \dots, Y_m$

$$P(X | e) = ?$$



# Алгоритм вероятностного вывода



$$P(X|\mathbf{e}) = \alpha P(X, \mathbf{e}) = \alpha \sum_y P(X, \mathbf{e}, y)$$

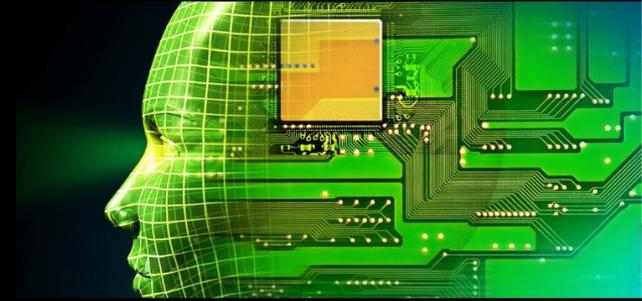
Анализ для  $n$  булевских переменных

Сложность по памяти:  $O(2^n)$

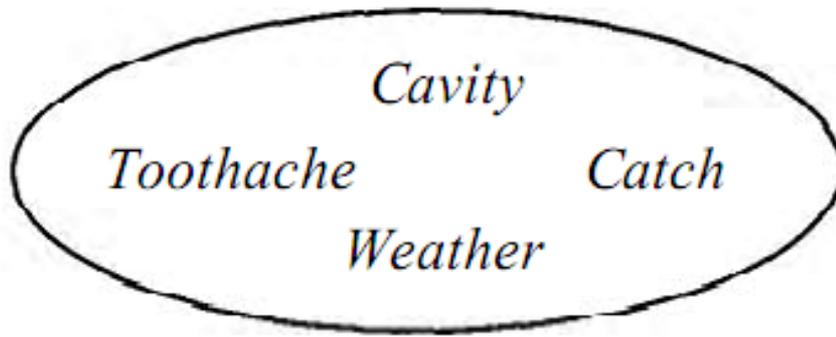
Сложность по времени:  $O(2^n)$



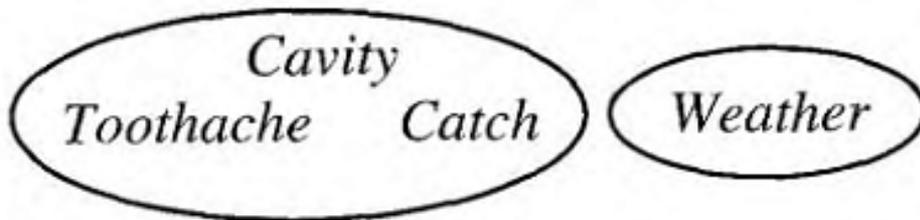
# Независимость



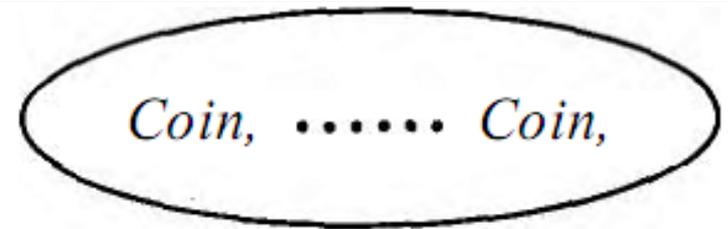
$$\mathbf{P}(\textit{Toothache}, \textit{Catch}, \textit{Cavity}, \textit{Weather}) = \mathbf{P}(\textit{Toothache}, \textit{Catch}, \textit{Cavity})\mathbf{P}(\textit{Weather})$$



decomposes  
into



(a)



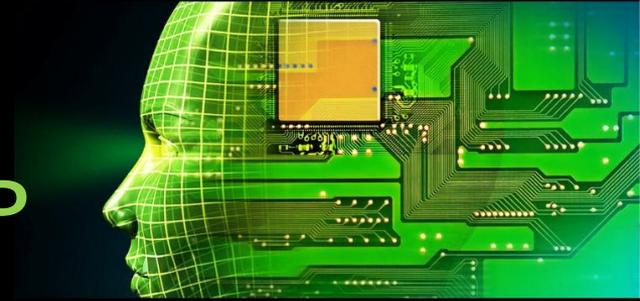
decomposes  
into



(b)



# Условная независимость



$$\mathbf{P}(Cavity|toothache \wedge catch) = \alpha \langle 0.108, 0.016 \rangle \approx \langle 0.871, 0.129 \rangle$$

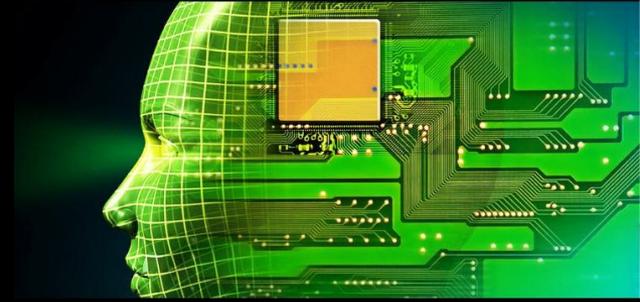
$$\mathbf{P}(Cavity|toothache \wedge catch) = \alpha \mathbf{P}(toothache \wedge catch|Cavity) \mathbf{P}(Cavity)$$

$$\mathbf{P}(toothache \wedge catch|Cavity) = \mathbf{P}(toothache|Cavity) \mathbf{P}(catch|Cavity)$$

$$\begin{aligned} \mathbf{P}(Toothache, Catch, Cavity) &= \mathbf{P}(Toothache, Catch|Cavity) \mathbf{P}(Cavity) \\ &= \mathbf{P}(Toothache|Cavity) \mathbf{P}(Catch|Cavity) \mathbf{P}(Cavity) \end{aligned}$$



# Размер представления



$n$  условно независимых симптомов

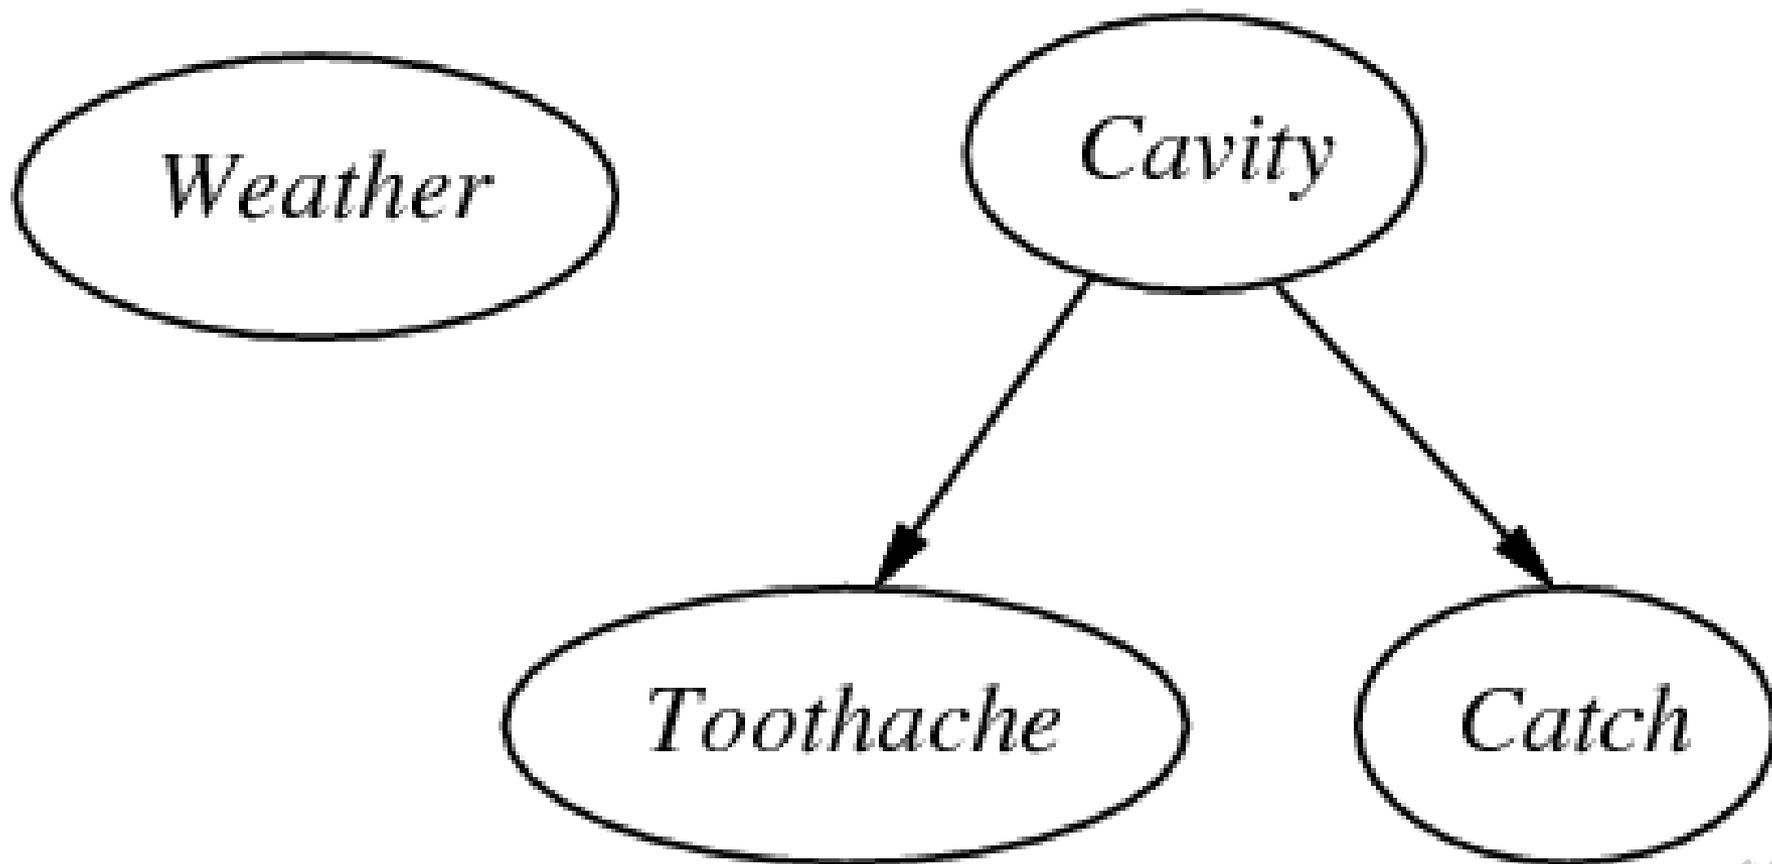
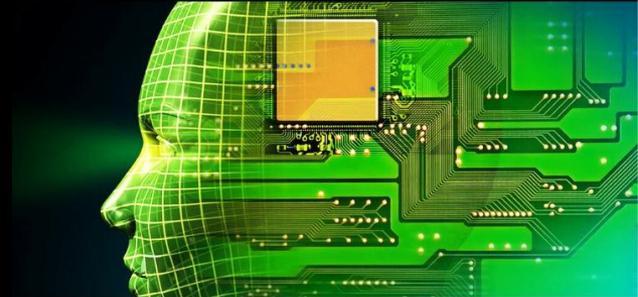
Сложность по памяти:  $O(n)$

Наивная байесовская модель:

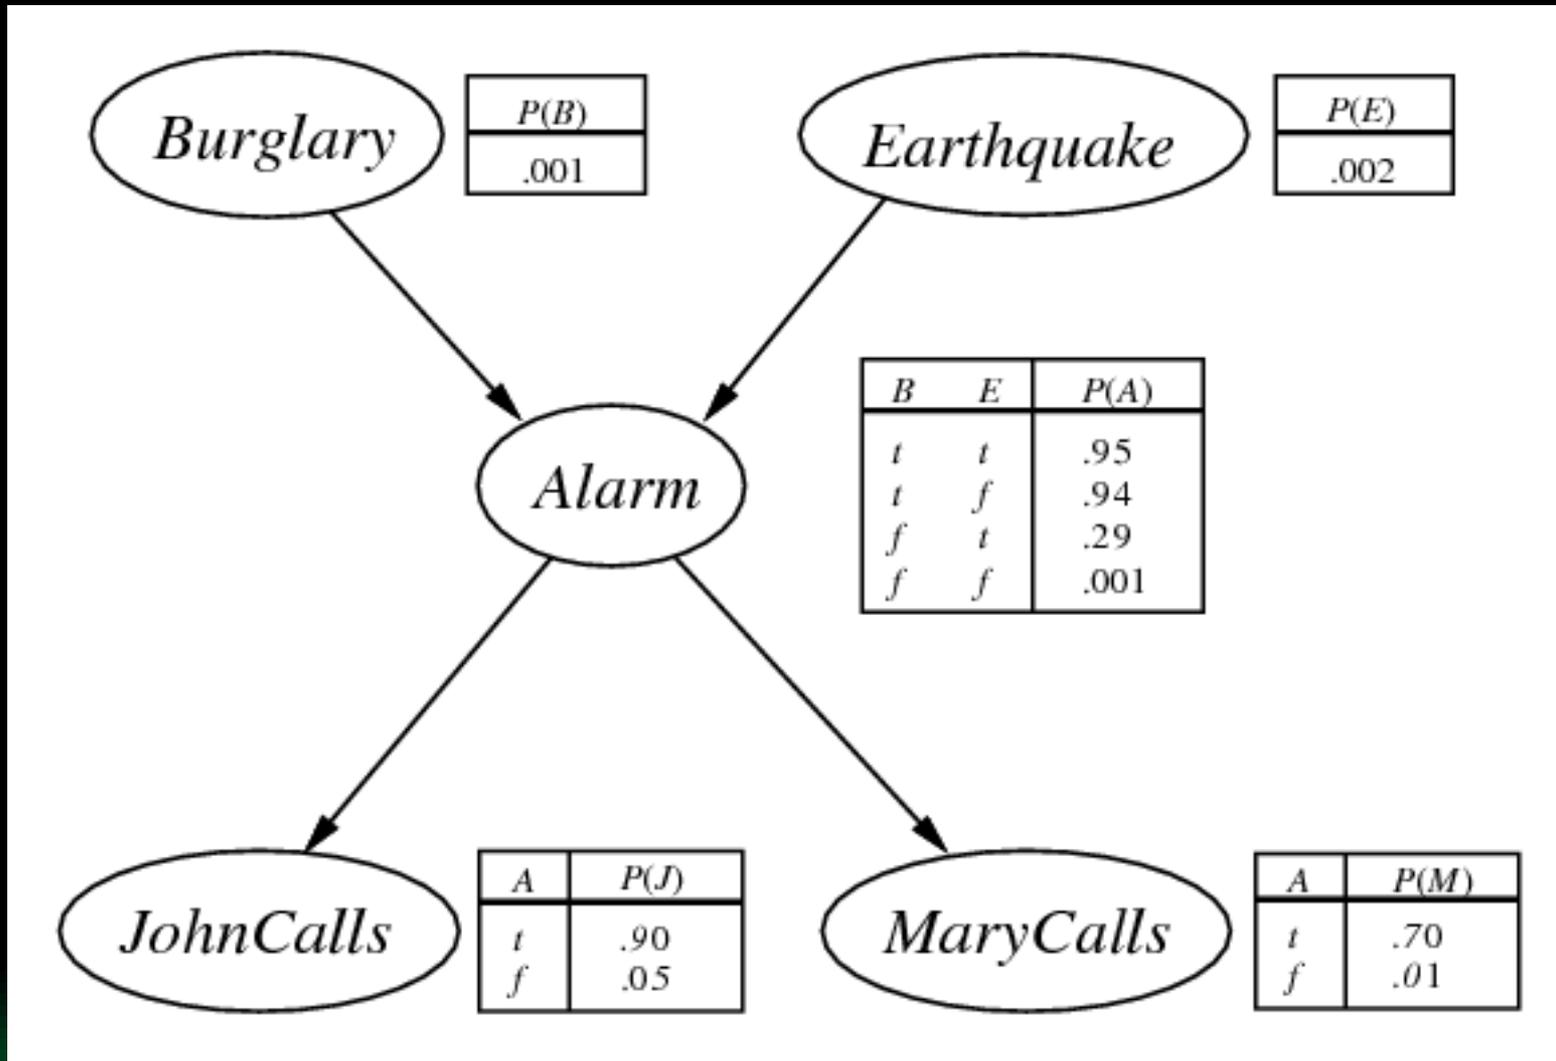
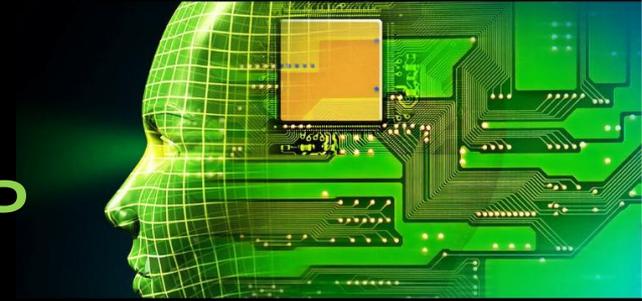
$$\mathbf{P}(Cause, Effect_1, \dots, Effect_n) = \mathbf{P}(Cause) \prod_i \mathbf{P}(Effect_i | Cause)$$



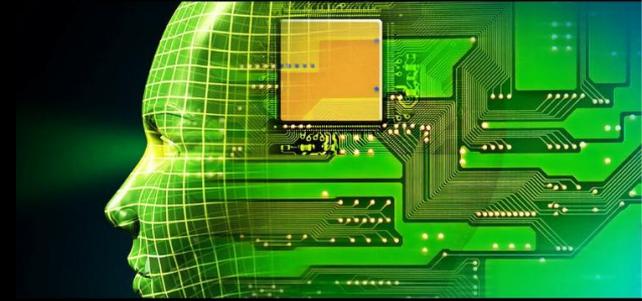
# Байесовская сеть



# Ещё одна байесовская сеть



# Семантика байесовской сети



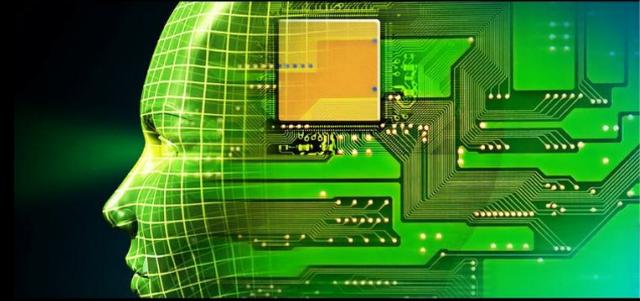
$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

Пример:

$$\begin{aligned} &P(j \wedge m \wedge a \wedge \neg b \wedge \neg e) \\ &= P(j|a)P(m|a)P(a|\neg b \wedge \neg e)P(\neg b)P(\neg e) \\ &= 0.90 \times 0.70 \times 0.001 \times 0.999 \times 0.998 = 0.0006'2. \end{aligned}$$



# Конструирование байесовской сети



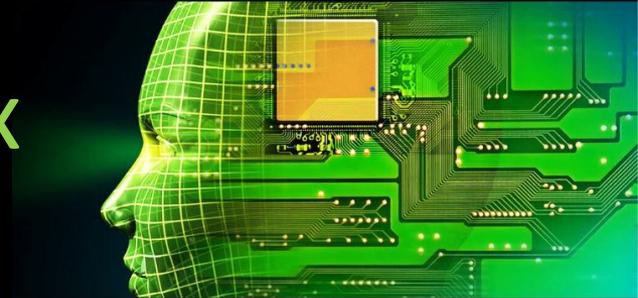
$$P(x_1, \dots, x_n) = P(x_n | x_{n-1}, \dots, x_1) P(x_{n-1}, \dots, x_1)$$

$$P(x_1, \dots, x_n) = P(x_n | x_{n-1}, \dots, x_1) P(x_{n-1} | x_{n-2}, \dots, x_1) \dots P(x_2 | x_1) P(x_1) =$$

$$= \prod_{i=1}^n P(x_i | x_{i-1}, \dots, x_1) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

$$P(X_i | X_{i-1}, \dots, X_1) = P(X_i | \text{parents}(X_i))$$

# Компактность байесовских сетей



Пусть:

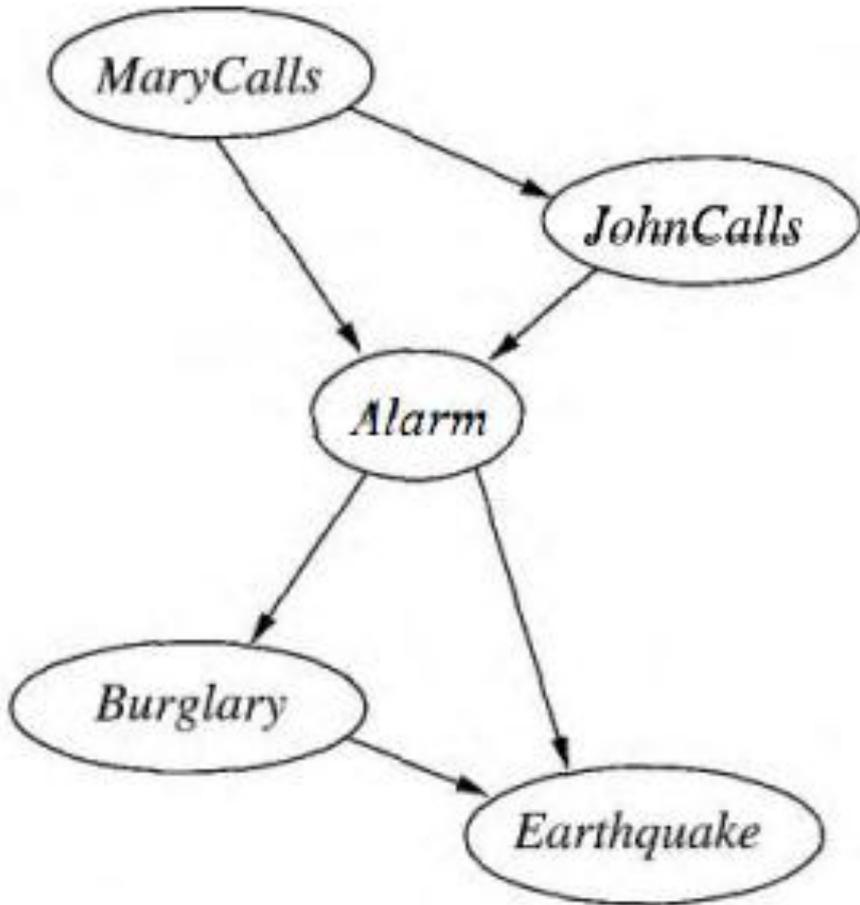
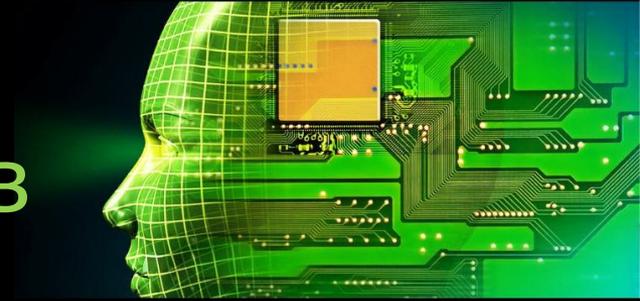
Количество входящих рёбер не больше  $k$   
 $n$  булевых переменных

Тогда:

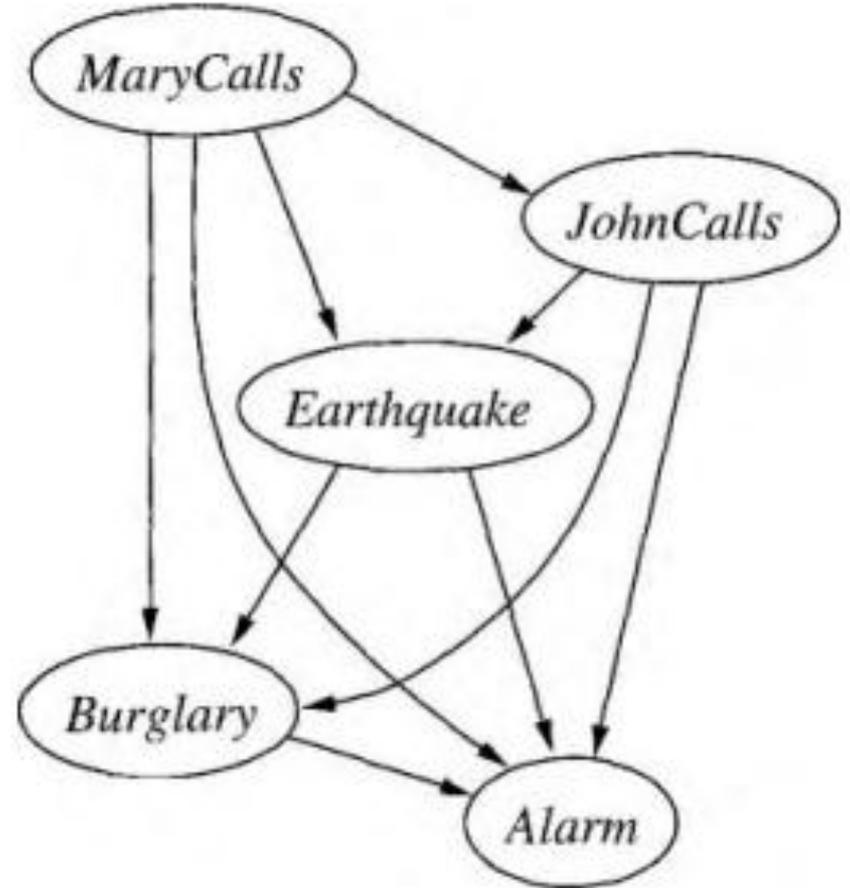
Размер представления:  $n2^k$  чисел



# Порядок добавления узлов



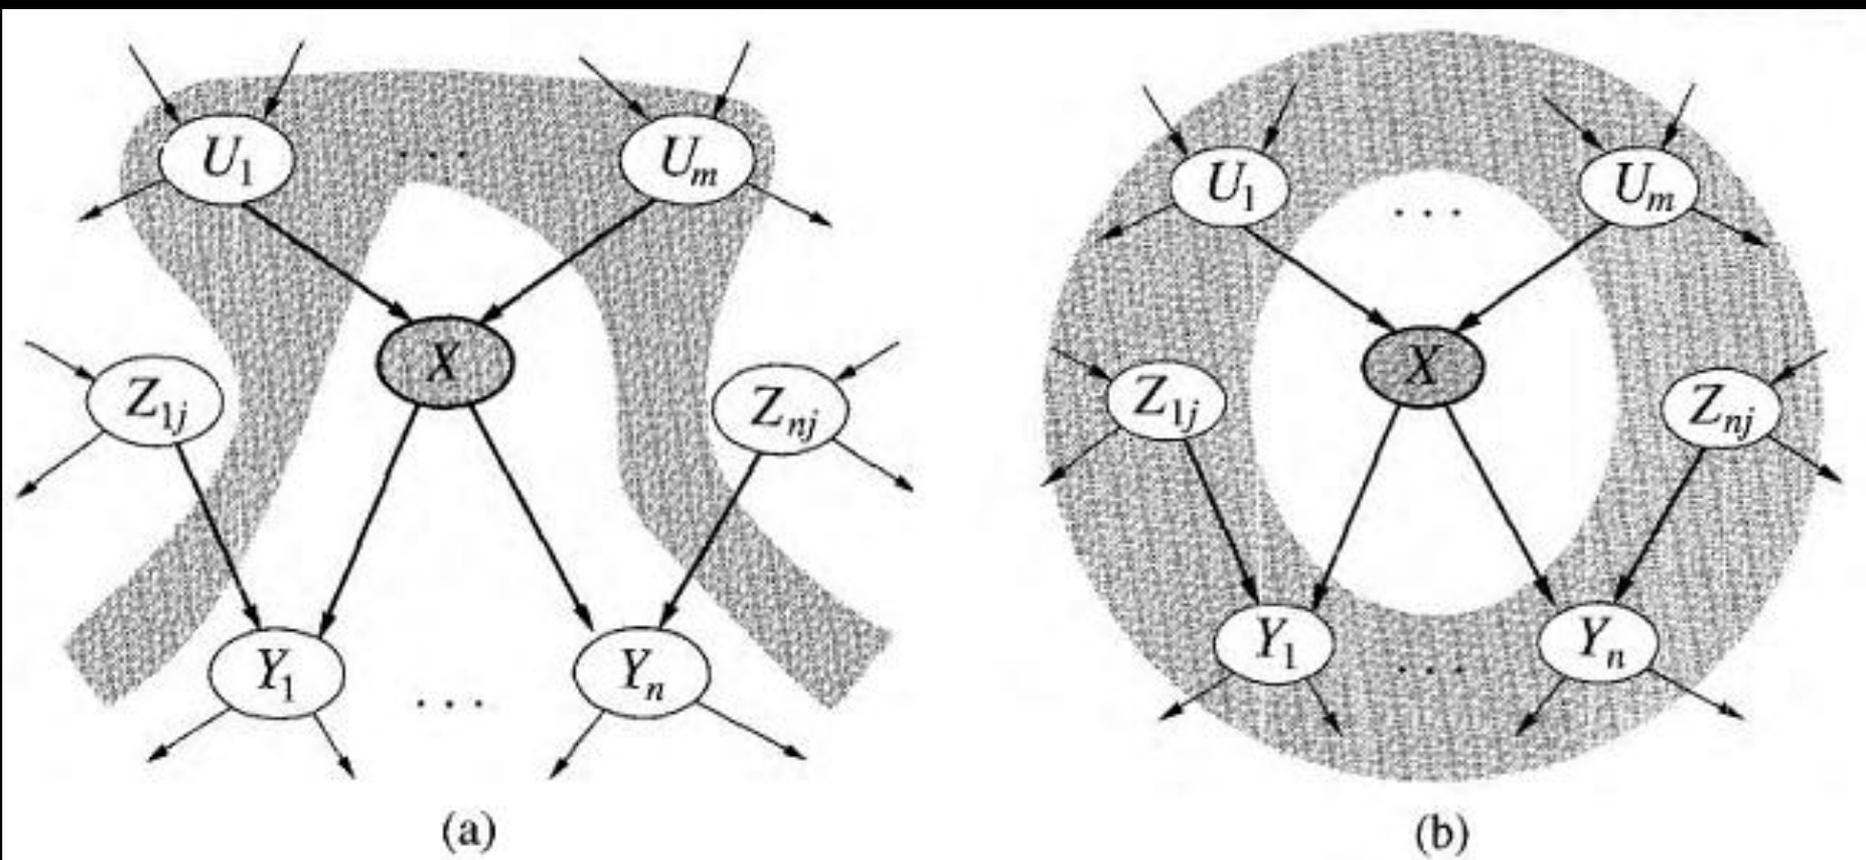
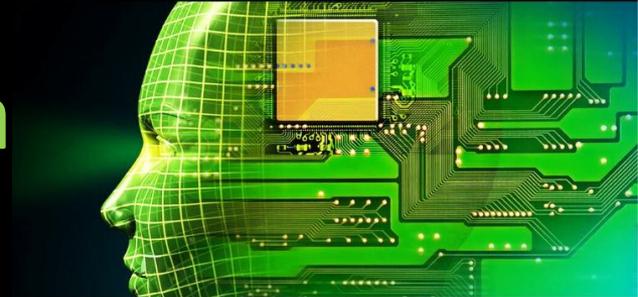
(a)



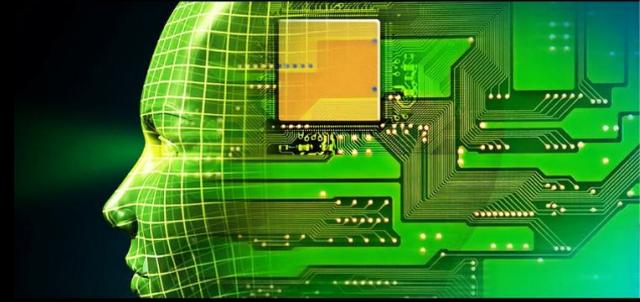
(b)



# Топологическая семантика байесовской сети



# Вероятностный вывод



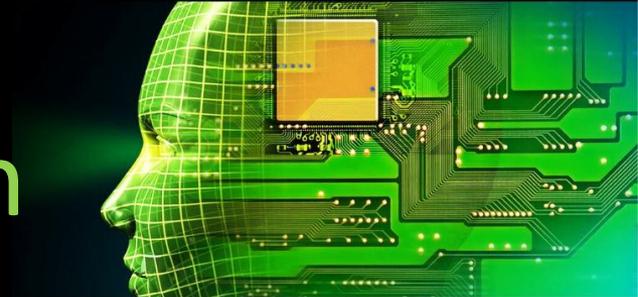
Обозначения:

- query variables  $X_i$
- evidence variables  $E_1, E_2, \dots, E_m$
- Nonevidence (hidden) variables  $Y_1, Y_2, \dots, Y_m$

$$P(X | e) = ?$$



# Inference by enumeration



$$\mathbf{P}(X|\mathbf{e}) = \alpha \mathbf{P}(X, \mathbf{e}) = \alpha \sum_{\mathbf{Y}} \mathbf{P}(X, \mathbf{e}, \mathbf{y})$$

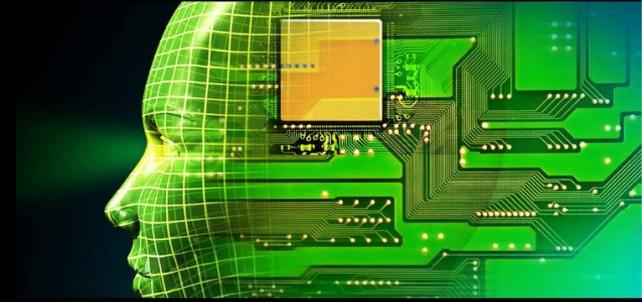
Пример:

$$\mathbf{P}(B|j, m) = \alpha \mathbf{P}(B, j, m) = \alpha \sum_e \sum_a \mathbf{P}(B, e, a, j, m)$$

$$P(b|j, m) = \alpha \sum_e \sum_a P(b)P(e)P(a|b, e)P(j|a)P(m|a)$$



# Сложность алгоритма



Сложность для сети с  $n$  булевыми переменными:

$$O(n2^n)$$

Оптимизация:

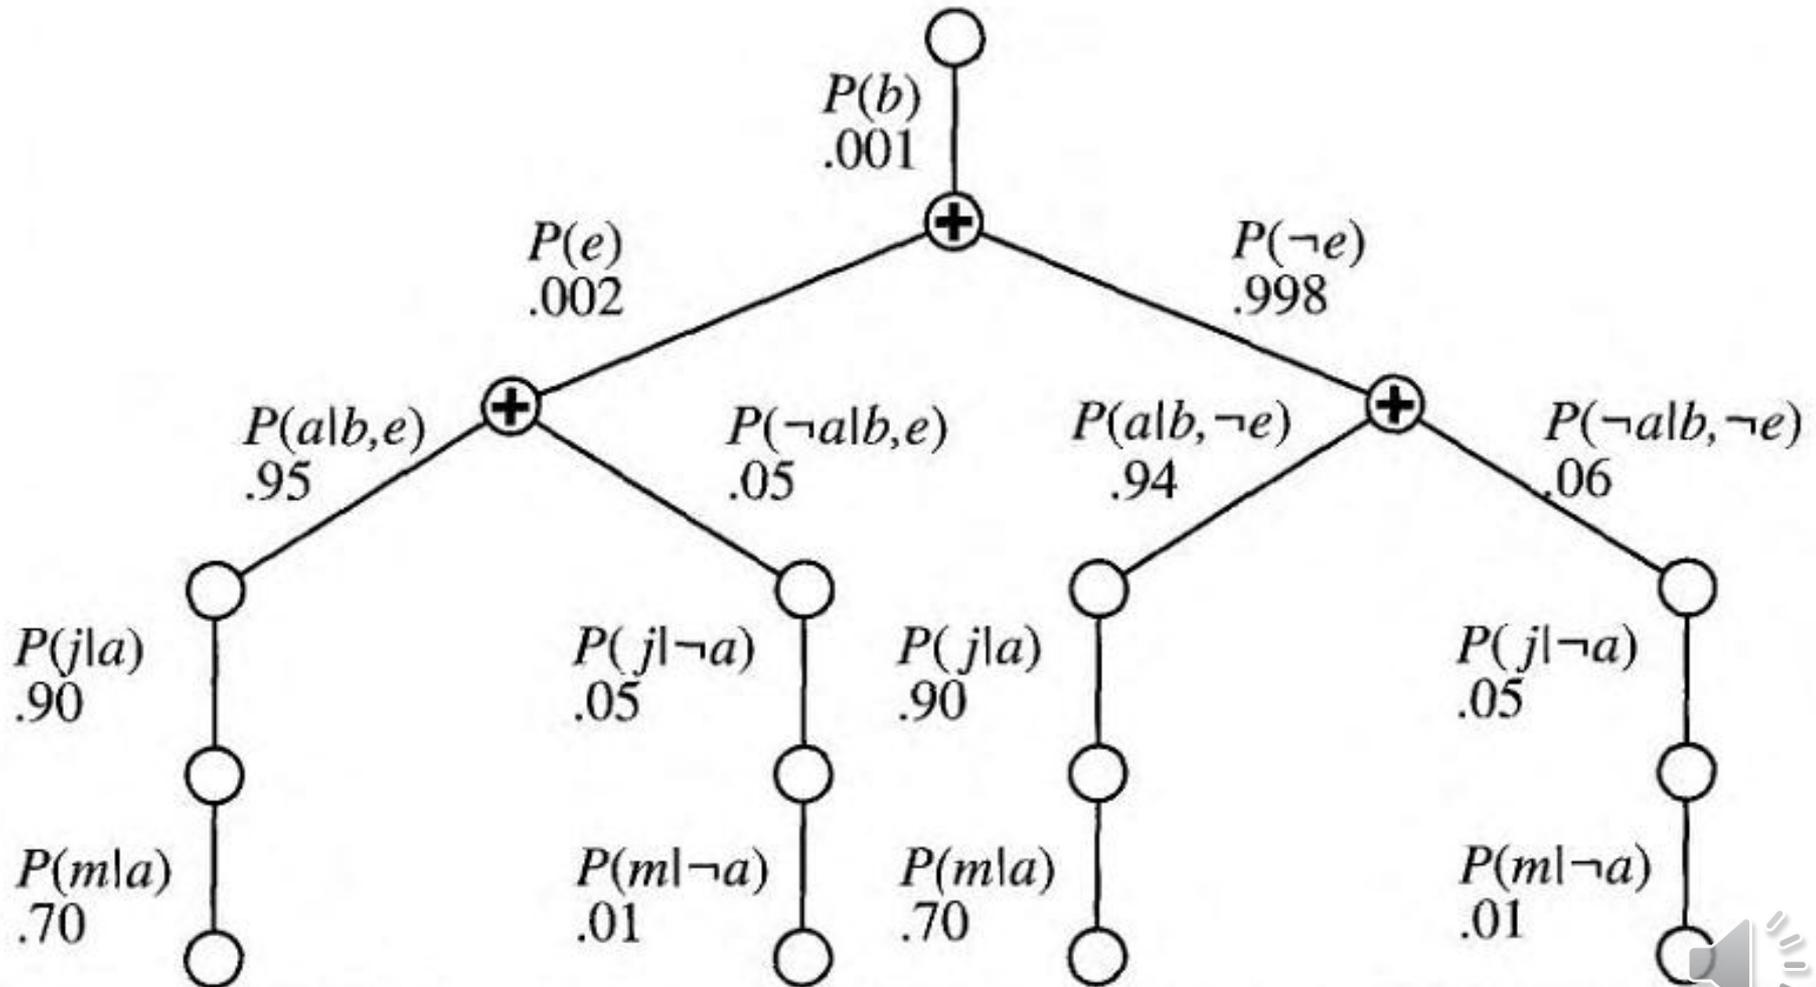
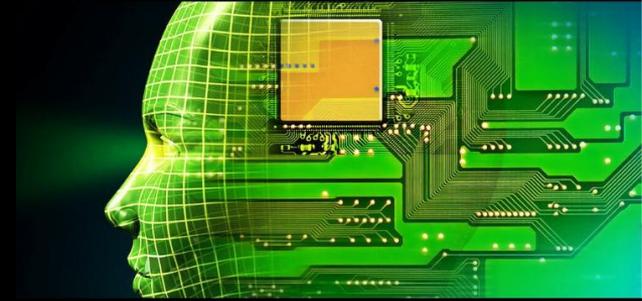
$$P(b|j, m) = \alpha P(b) \sum_e P(e) \sum_a P(a|b, e) P(j|a) P(m|a)$$

Сложность по памяти:  $O(n)$

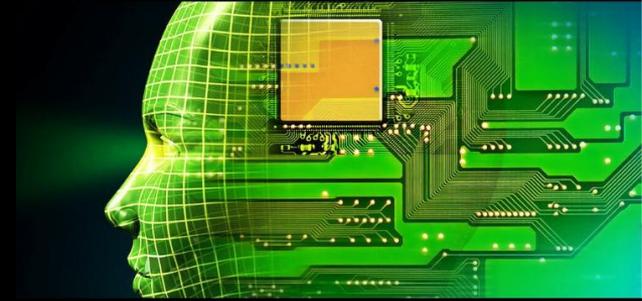
Сложность по времени:  $O(2^n)$



# Процесс вычислений в алгоритме



# The variable elimination algorithm



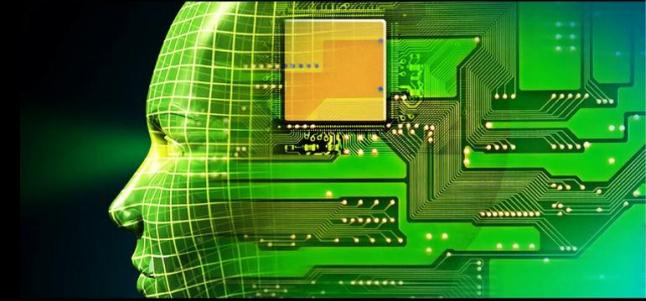
$$\mathbf{P}(B|j, m) = \alpha \underbrace{\mathbf{P}(B)}_B \sum_e \underbrace{P(e)}_E \sum_a \underbrace{\mathbf{P}(a|B, e)}_A \underbrace{P(j|a)}_J \underbrace{P(m|a)}_M$$

Идея алгоритма:

Динамическое программирование



# Pointwise product

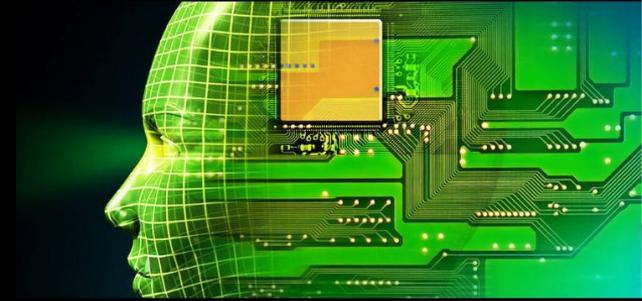


$$\mathbf{f}(X_1 \dots X_j, Y_1 \dots Y_k, Z_1 \dots Z_l) = \mathbf{f}_1(X_1 \dots X_j, Y_1 \dots Y_k) \mathbf{f}_2(Y_1 \dots Y_k, Z_1 \dots Z_l)$$

$A$	$B$	$\mathbf{f}_1(A, B)$	$B$	$C$	$\mathbf{f}_2(B, C)$	$A$	$B$	$C$	$\mathbf{f}_3(A, B, C)$
T	T	.3	T	T	.2	T	T	T	.3 × .2
T	F	.7	T	F	.8	T	T	F	.3 × .8
F	T	.9	F	T	.6	T	F	T	.7 × .6
F	F	.1	F	F	.4	T	F	F	.7 × .4
						F	T	T	.9 × .2
						F	T	F	.9 × .8
						F	F	T	.1 × .6
						F	F	F	.1 × .4



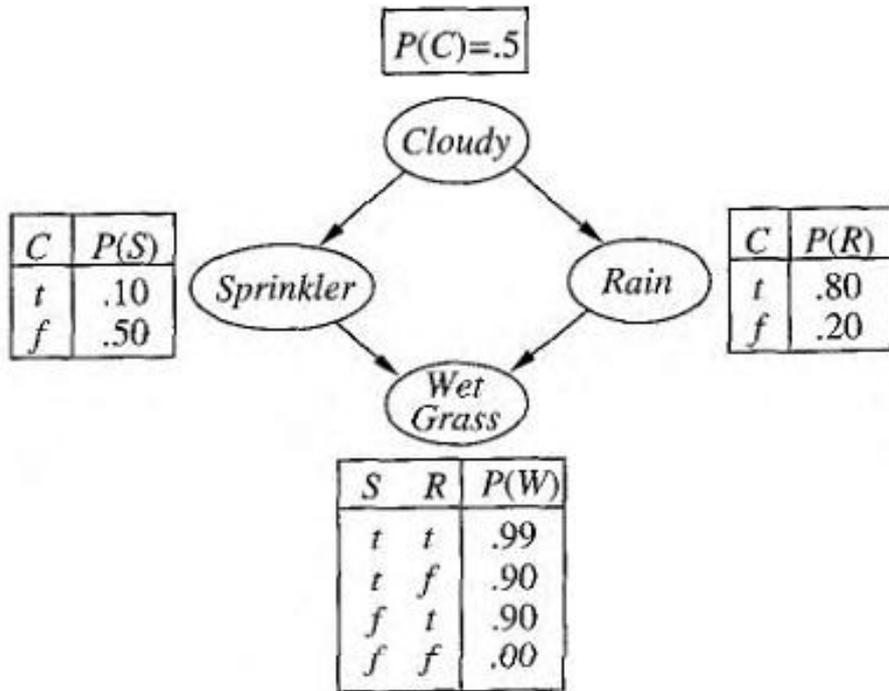
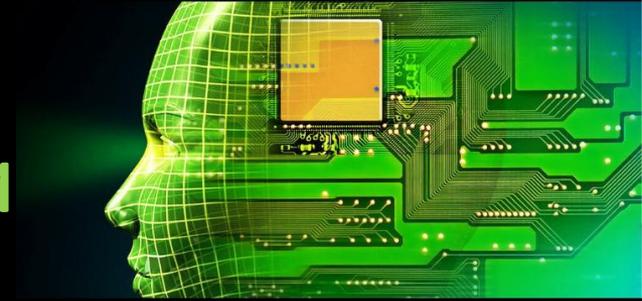
# Сложность алгоритма



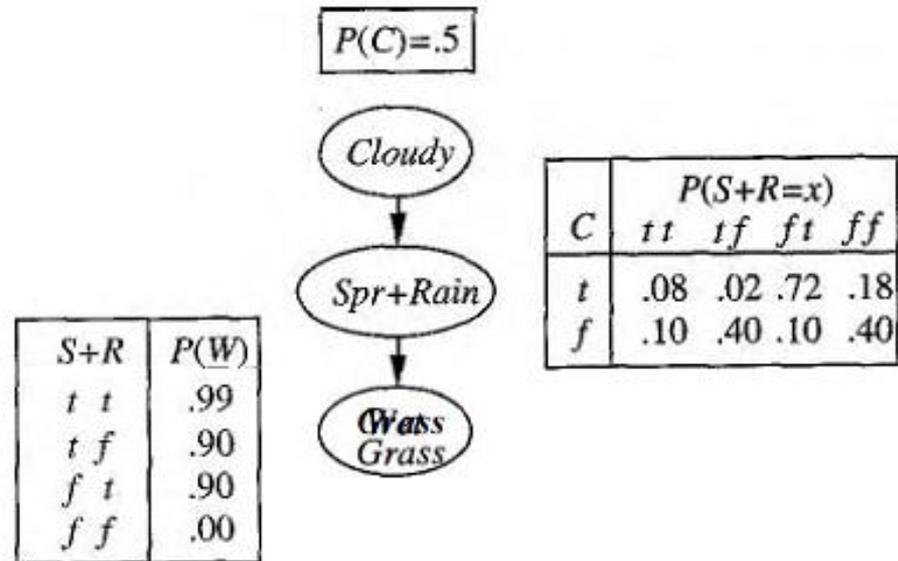
Тип сети	Сложность (по времени и по памяти)
Singly connected network (polytree)	Линейная
Multiply connected network	Экспоненциальная



# Алгоритмы кластеризации

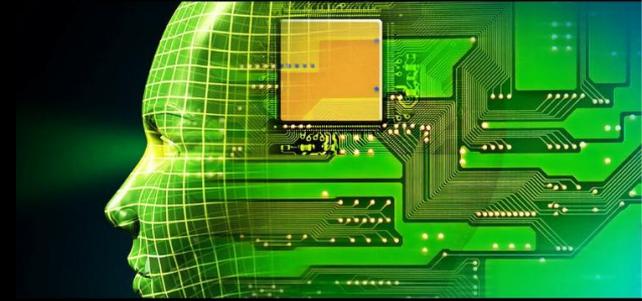


(a)

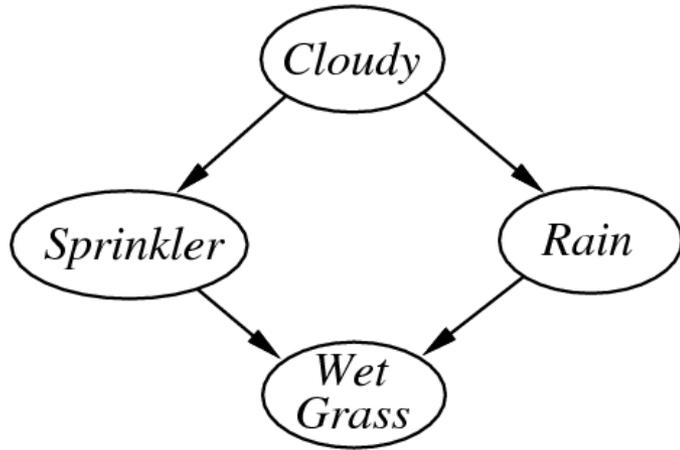


(b)





$$P(C) = .5$$



<i>C</i>	$P(S)$
<i>t</i>	.10
<i>f</i>	.50

<i>C</i>	$P(R)$
<i>t</i>	.80
<i>f</i>	.20

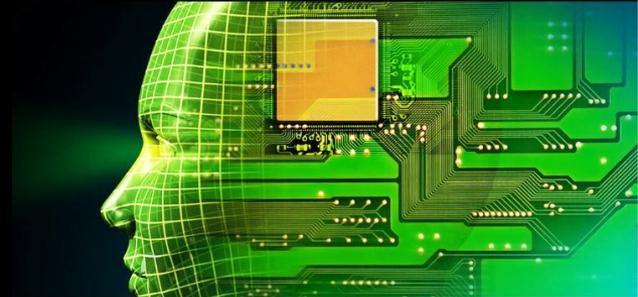
<i>S</i>	<i>R</i>	$P(W)$
<i>t</i>	<i>t</i>	.99
<i>t</i>	<i>f</i>	.90
<i>f</i>	<i>t</i>	.90
<i>f</i>	<i>f</i>	.00

# Direct sampling

$P(\textit{Cloudy})$	(0.5, 0.5)	<b>true</b>
$P(\textit{Sprinkler} \mid \textit{Cloudy} = \textit{true})$	(0.1, 0.9)	<b>false</b>
$P(\textit{Rain} \mid \textit{Cloudy} = \textit{true})$	(0.8, 0.2)	<b>true</b>
$P(\textit{WetGrass} \mid \textit{Sprinkler} = \textit{false}, \textit{Rain} = \textit{true})$	(0.9, 0.1)	<b>true</b>



# Почему это работает



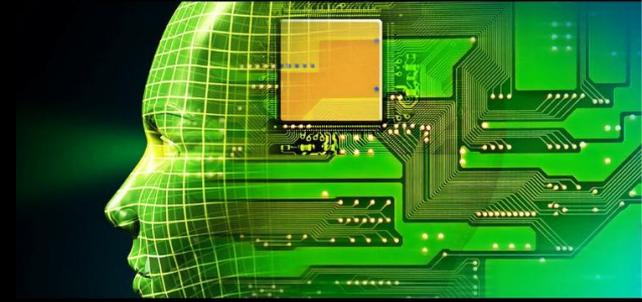
$$S_{PS}(x_1 \dots x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

$$S_{PS}(x_1 \dots x_n) = P(x_1 \dots x_n)$$

$$P(x_1, \dots, x_m) \approx N_{PS}(x_1, \dots, x_m) / N$$



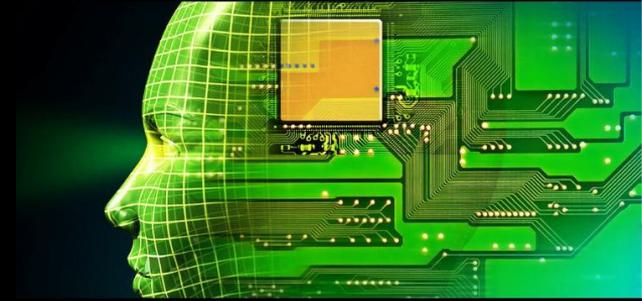
# Rejection sampling



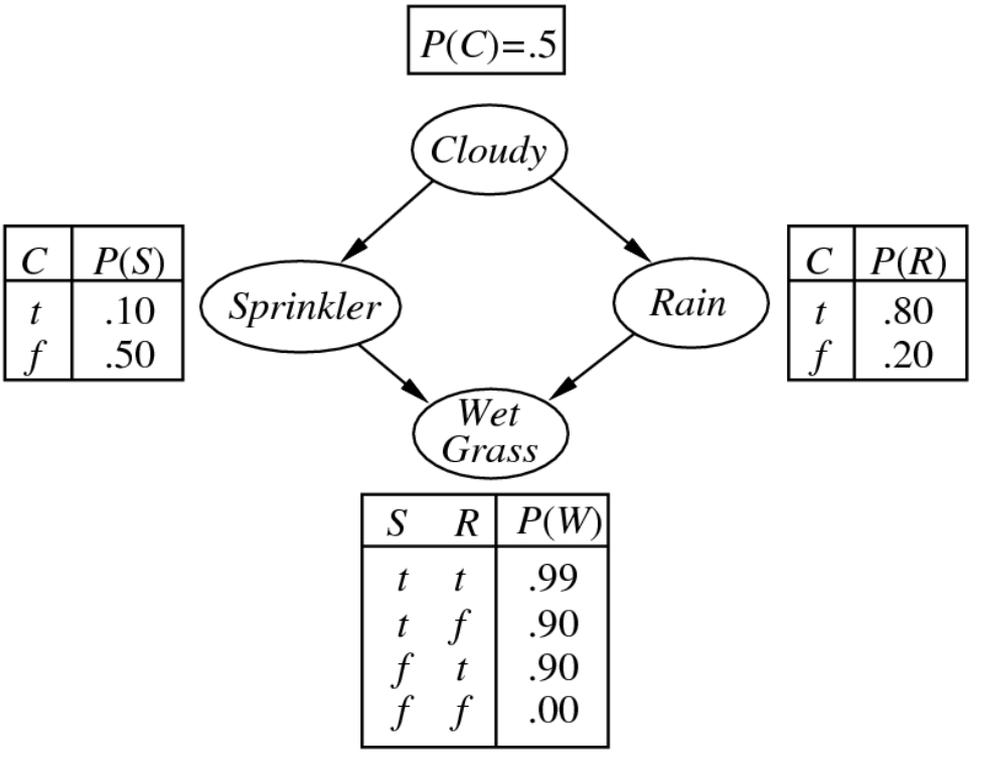
$$P(X|e) = \frac{P(X, e)}{P(e)}$$

Исключаем выборки, в которых нет события  $e$





# Likelihood weighting

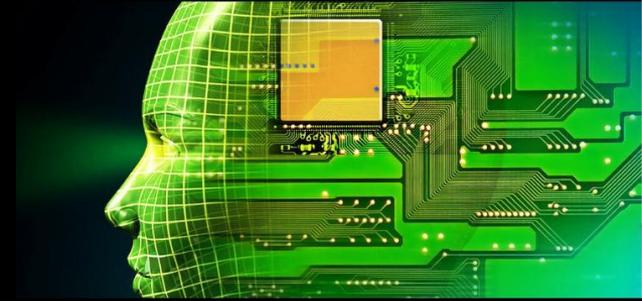


$P(\text{Rain} \mid \text{Sprinkler} = \text{true}, \text{WetGrass} = \text{true}) = ?$

1.  $P(\text{Cloudy}) = (0.5, 0.5) \rightarrow \text{true}$
2.  $w = w * P(\text{Sprinkler} = \text{true} \mid \text{Cloudy} = \text{true}) = 0.1$
3.  $P(\text{Rain} \mid \text{Cloudy} = \text{true}) = (0.8, 0.2) \rightarrow \text{true}$
4.  $w = w * P(\text{WetGrass} = \text{true} \mid \text{Sprinkler} = \text{true}, \text{Rain} = \text{true}) = 0.099$



# Почему это работает

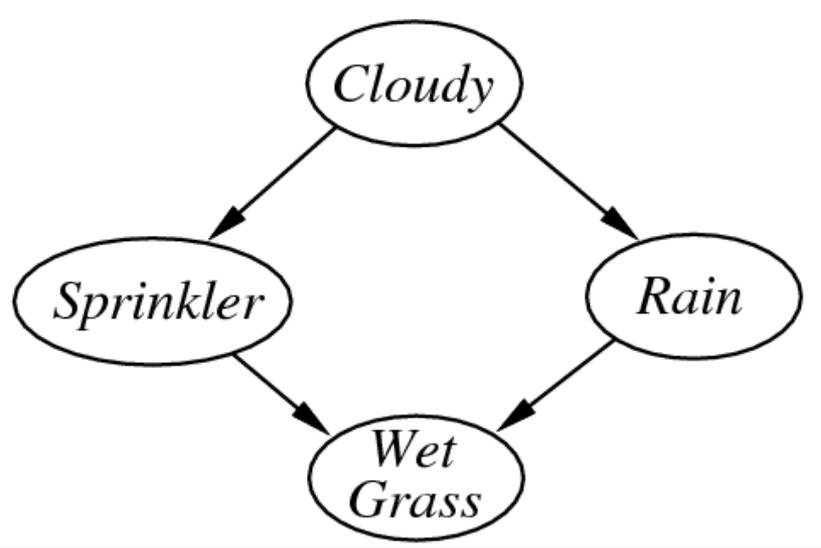


$$S_{WS}(\mathbf{z}, \mathbf{e}) = \prod_{i=1}^l P(z_i | \text{parents}(Z_i))$$

$$w(\mathbf{z}, \mathbf{e}) = \prod_{i=1}^m P(e_i | \text{parents}(E_i))$$

$$\begin{aligned} S_{WS}(\mathbf{z}, \mathbf{e})w(\mathbf{z}, \mathbf{e}) &= \prod_{i=1}^l P(z_i | \text{parents}(Z_i)) \prod_{i=1}^m P(e_i | \text{parents}(E_i)) \\ &= P(\mathbf{z}, \mathbf{e}), \end{aligned}$$





# Markov chain Monte Carlo (MCMC) algorithm

$P(\text{Rain} \mid \text{Sprinkler} = \text{true}, \text{WetGrass} = \text{true}) = ?$

$\text{Cloudy} \rightarrow \text{true}, \quad \text{Rain} \rightarrow \text{false}$

$[\text{true}, \text{true}, \text{false}, \text{true}]$

$P(\text{Cloudy} \mid \text{Sprinkler} = \text{true}, \text{Rain} = \text{false}) \rightarrow \text{Cloudy} = \text{false}$

$[\text{false}, \text{true}, \text{false}, \text{true}]$

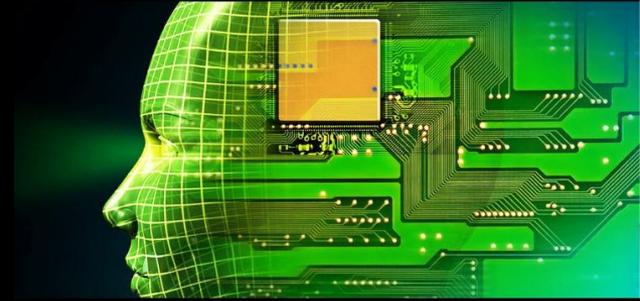
$P(\text{Rain} \mid \text{Cloudy} = \text{false}, \text{Sprinkler} = \text{true}, \text{WetGrass} = \text{true}) \rightarrow \text{Rain} = \text{true}$

$[\text{false}, \text{true}, \text{true}, \text{true}]$

.....



# Почему это работает - 1



$$\pi_{t+1}(x') = \sum_x \pi_t(x) q(x \rightarrow x'), \quad \text{где}$$

$\pi_t(x)$  – вероятность находиться в состоянии  $x$  в момент времени  $t$

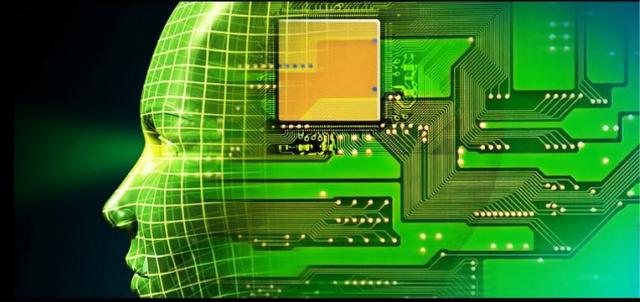
$q(x \rightarrow x')$  – вероятность перехода из состояния  $x$  в состояние  $x'$

Равновесное распределение вероятностей:  $\pi_{t+1} = \pi_t$

$$\forall x' \quad \pi(x') = \sum_x \pi(x) q(x \rightarrow x')$$



# Почему это работает - 2



Property of *detailed balance*:

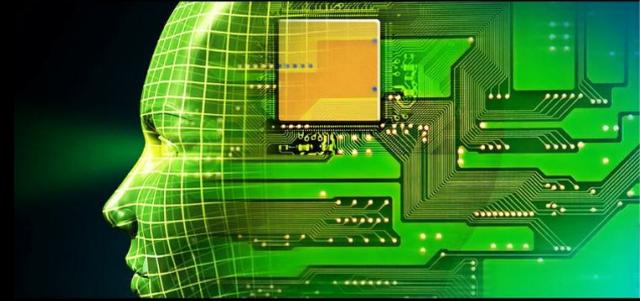
$$\forall x, x' \quad \pi(x)q(x \rightarrow x') = \pi(x')q(x' \rightarrow x)$$

Тогда  $\pi(x)$  - равновесное распределение вероятностей:

$$\begin{aligned} \forall x' \quad \sum_x \pi(x)q(x \rightarrow x') &= \sum_x \pi(x')q(x' \rightarrow x) = \\ &= \pi(x') \sum_x q(x' \rightarrow x) = \pi(x') \end{aligned}$$



# Почему это работает - 3



## *Gibbs sampler:*

$$q(\mathbf{x} \rightarrow \mathbf{x}') = q((x_i, \bar{\mathbf{x}}_i) \rightarrow (x'_i, \bar{\mathbf{x}}_i)) = P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e})$$

$X_i$  - переменная для генерации

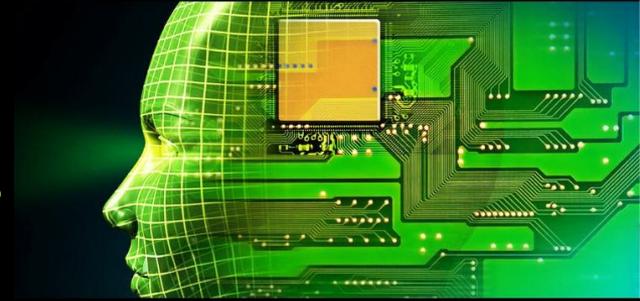
$\bar{X}_i$  - все остальные скрытые переменные

В этом случае равновесной будет апостериорная вероятность:

$$\begin{aligned} \pi(\mathbf{x})q(\mathbf{x} \rightarrow \mathbf{x}') &= P(\mathbf{x}|\mathbf{e})P(x'_i|\bar{\mathbf{x}}_i, \mathbf{e}) = P(x_i, \bar{\mathbf{x}}_i|\mathbf{e})P(x'_i|\bar{\mathbf{x}}_i, \mathbf{e}) \\ &= P(x_i|\bar{\mathbf{x}}_i, \mathbf{e})P(\bar{\mathbf{x}}_i|\mathbf{e})P(x'_i|\bar{\mathbf{x}}_i, \mathbf{e}) \quad (\text{using the chain rule on the first term}) \\ &= P(x_i|\bar{\mathbf{x}}_i, \mathbf{e})P(x'_i, \bar{\mathbf{x}}_i|\mathbf{e}) \quad (\text{using the chain rule backwards}) \\ &= \pi(\mathbf{x}')q(\mathbf{x}' \rightarrow \mathbf{x}). \end{aligned}$$



# Почему это работает - 4



## *Markov blanket:*

- Родители
- Дети
- Родители детей

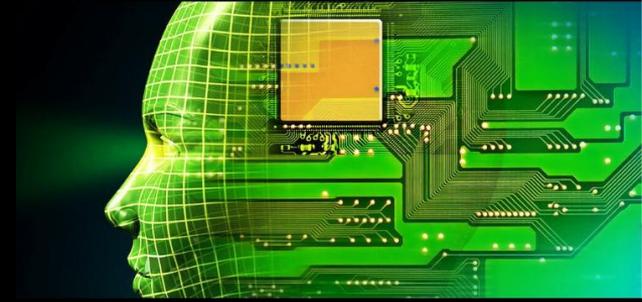
Факт №1:  $P(x'_i | \bar{\mathbf{x}}_i, \mathbf{e}) = P(x'_i | mb(X_i))$

Факт №2:

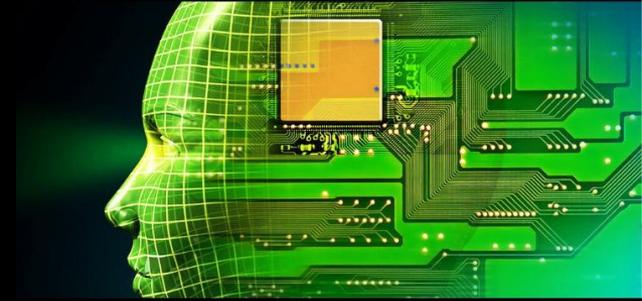
$$P(x'_i | mb(X_i)) = \alpha P(x'_i | parents(X_i)) \times \prod_{Y_j \in Children(X_i)} P(y_j | parents(Y_j))$$



# Temporal model



# Обозначения

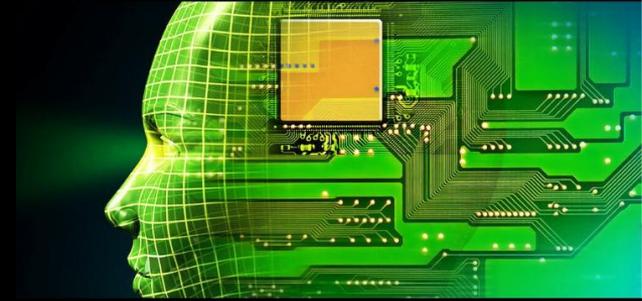


- $X_t$  – множество ненаблюдаемых случайных величин в момент времени  $t$
- $E_t$  – множество наблюдаемых случайных величин в момент времени  $t$

$$X_{a:b} = \bigcup_{i=a}^b X_i$$



# Предположения



Процесс:

- Стационарный
- Марковский:

$$P(X_t | X_{0:t-1}) = P(X_t | X_{t-1})$$

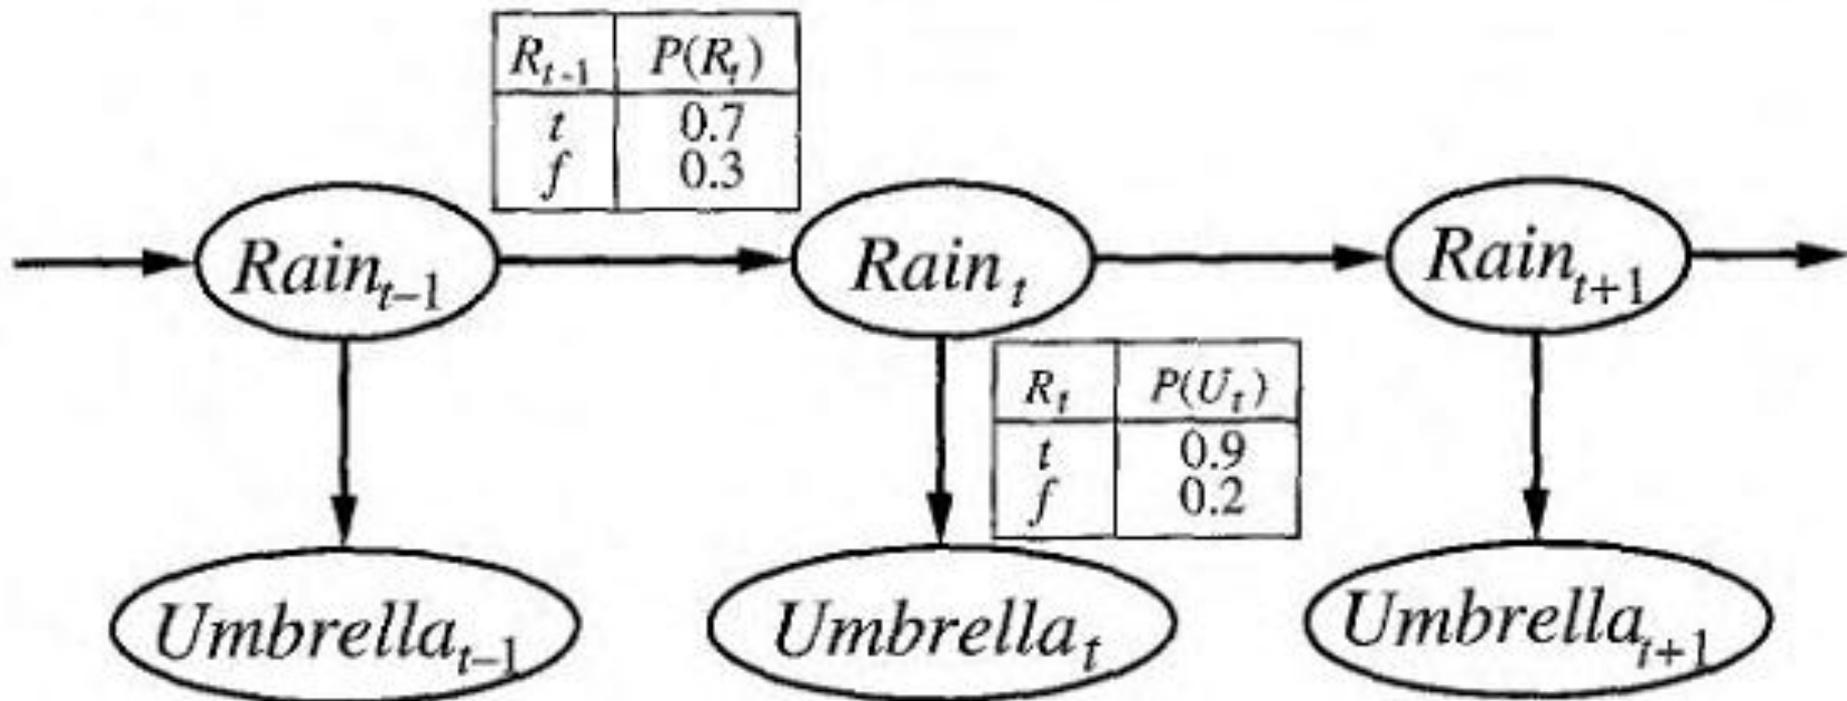
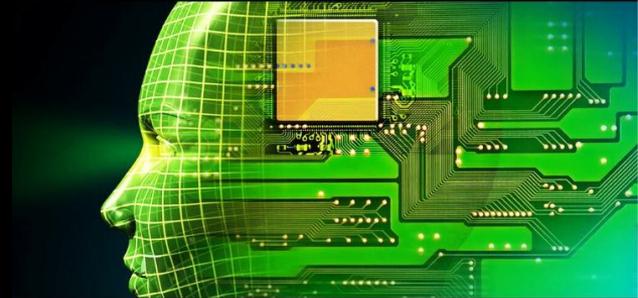


Модель наблюдения:

$$P(E_t | X_{0:t}, E_{0:t-1}) = P(E_t | X_t)$$



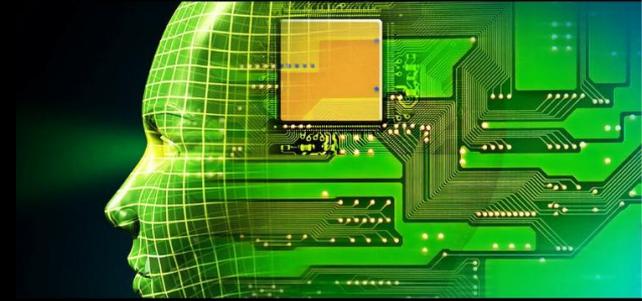
# Байесовская сеть



$$\mathbf{P}(\mathbf{X}_0, \mathbf{X}_1, \dots, \mathbf{X}_t, \mathbf{E}_1, \dots, \mathbf{E}_t) = \mathbf{P}(\mathbf{X}_0) \prod_{i=1}^t \mathbf{P}(\mathbf{X}_i | \mathbf{X}_{i-1}) \mathbf{P}(\mathbf{E}_i | \mathbf{X}_i)$$



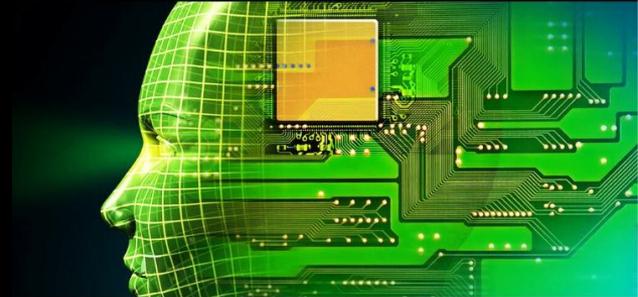
# Inference in Temporal Models



Название задачи	Найти
Filtering (monitoring)	$P(X_t   e_{1:t})$
Prediction	$P(X_{t+k}   e_{1:t})$
Smoothing (hindsight)	$P(X_k   e_{1:t})$
Most likely explanation	$P(x_{1:t}   e_{1:t})$



# Filtering and prediction



Рекурсивное вычисление Filtering:

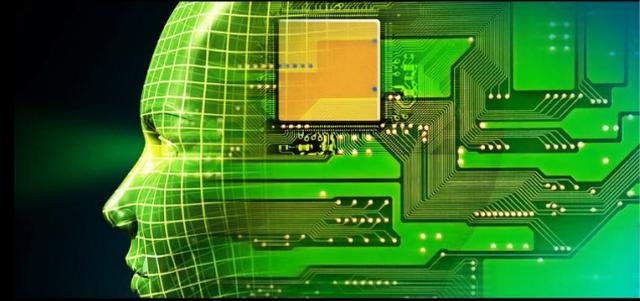
$$\begin{aligned}\mathbf{P}(\mathbf{X}_{t+1}|\mathbf{e}_{1:t+1}) &= \mathbf{P}(\mathbf{X}_{t+1}|\mathbf{e}_{1:t}, \mathbf{e}_{t+1}) \quad (\text{dividing up the evidence}) \\ &= \alpha \mathbf{P}(\mathbf{e}_{t+1}|\mathbf{X}_{t+1}, \mathbf{e}_{1:t}) \mathbf{P}(\mathbf{X}_{t+1}|\mathbf{e}_{1:t}) \quad (\text{using Bayes' rule}) \\ &= a \mathbf{P}(\mathbf{e}_{t+1}|\mathbf{X}_{t+1}) \mathbf{P}(\mathbf{X}_{t+1}|\mathbf{e}_{1:t}) \quad (\text{by the Markov property of evidence})\end{aligned}$$

Развёртываем Prediction:

$$\begin{aligned}\mathbf{P}(\mathbf{X}_{t+1}|\mathbf{e}_{1:t+1}) &= \alpha \mathbf{P}(\mathbf{e}_{t+1}|\mathbf{X}_{t+1}) \sum_{\mathbf{x}_t} \mathbf{P}(\mathbf{X}_{t+1}|\mathbf{x}_t, \mathbf{e}_{1:t}) P(\mathbf{x}_t|\mathbf{e}_{1:t}) \\ &= a \mathbf{P}(\mathbf{e}_{t+1}|\mathbf{X}_{t+1}) \sum_{\mathbf{x}_t} \mathbf{P}(\mathbf{X}_{t+1}|\mathbf{x}_t) P(\mathbf{x}_t|\mathbf{e}_{1:t}) \quad (\text{using the Markov property}).\end{aligned}$$



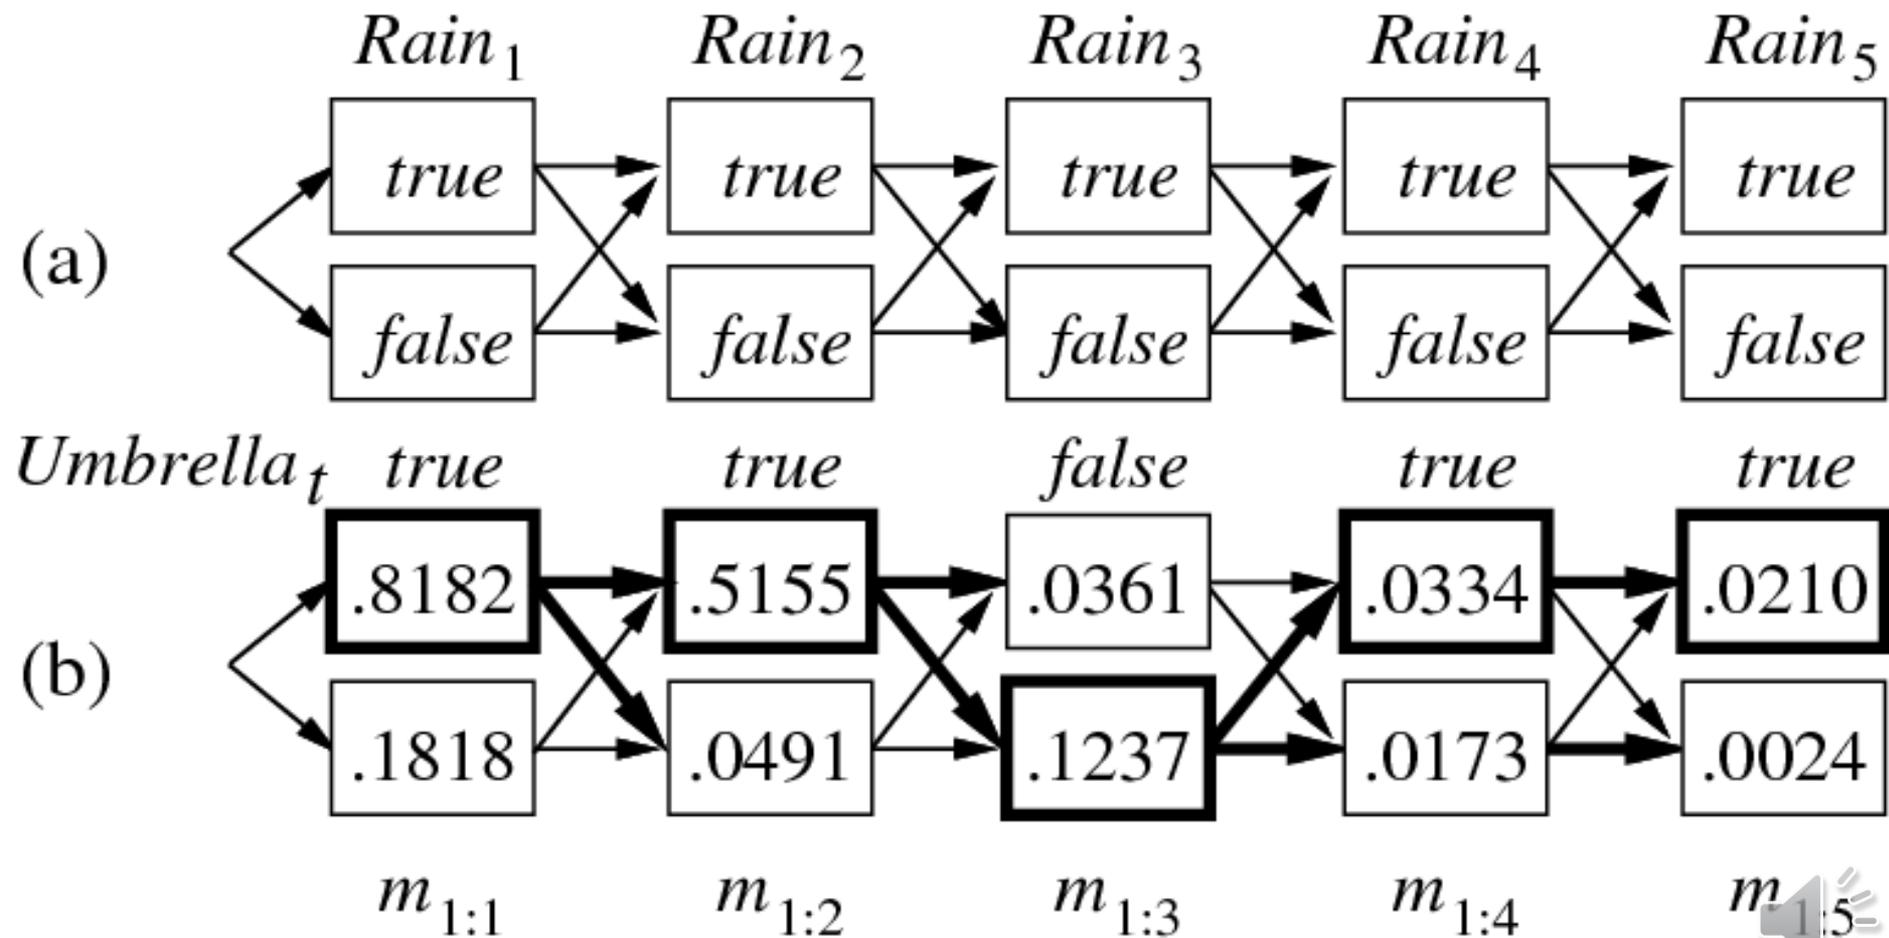
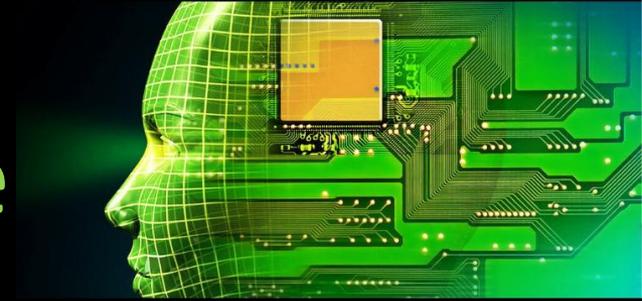
# Smoothing



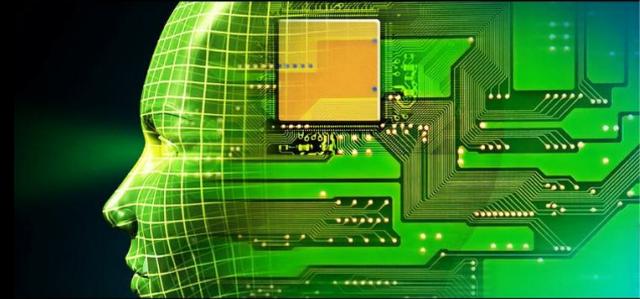
$$\begin{aligned}\mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:t}) &= \mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:k}, \mathbf{e}_{k+1:t}) \\ &= \alpha \mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:k}) \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k, \mathbf{e}_{1:k}) \quad (\text{using Bayes' rule}) \\ &= \alpha \mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:k}) \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k) \quad (\text{using conditional independence}) \\ &= \alpha \mathbf{f}_{1:k} \mathbf{b}_{k+1:t},\end{aligned}$$

$$\begin{aligned}\mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k) &= \sum_{\mathbf{x}_{k+1}} \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k, \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k) \quad (\text{conditioning on } \mathbf{X}_{k+1}) \\ &= \sum_{\mathbf{x}_{k+1}} P(\mathbf{e}_{k+1:t} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k) \quad (\text{by conditional independence}) \\ &= \sum_{\mathbf{x}_{k+1}} P(\mathbf{e}_{k+1}, \mathbf{e}_{k+2:t} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k) \\ &= \sum_{\mathbf{x}_{k+1}} P(\mathbf{e}_{k+1} | \mathbf{x}_{k+1}) P(\mathbf{e}_{k+2:t} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k),\end{aligned}$$

# The most likely sequence



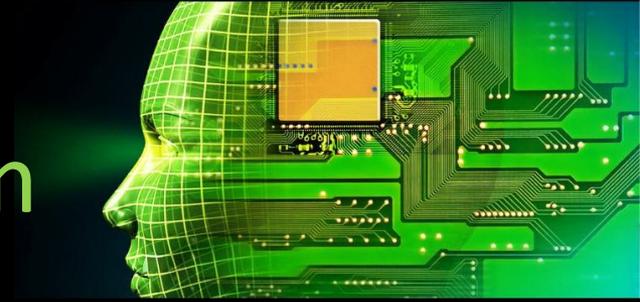
# Сложность алгоритмов



Название задачи	Время	Память
Filtering (monitoring)	$O(t)$	$O(1)$
Prediction		
Smoothing (hindsight)	$O(t)$	
Most likely explanation	$O(t)$	$O(t)$



# Forward-backward algorithm



Хочется узнать  $P(X_k | e_{1:t})$  для всех  $k$ . Что делать?

Forward-backward algorithm:

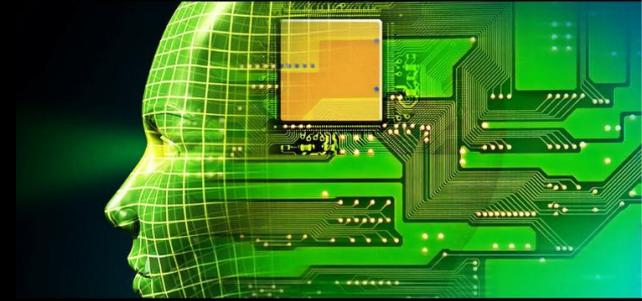
1. Forward filtering от 1 до  $t$   
(запоминая результаты вычислений)
2. Backward recursion от  $t$  до 1

Сложность во времени:  $O(t)$

Сложность по памяти:  $O(|f|t)$ , где  $|f|$  - размер forward message



# Hidden Markov Model (HMM)



HMM: состояние – одна дискретная случайная величина

$P(X_t | X_{t-1}) \rightarrow$  матрица  $T$  размера  $S \times S$ :

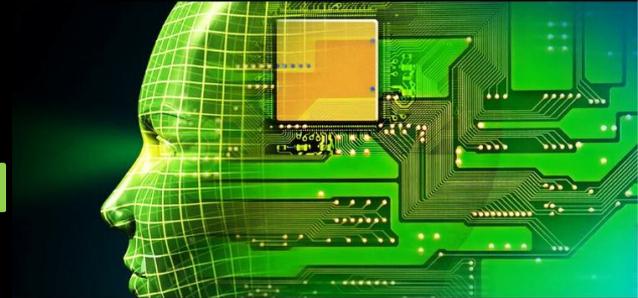
$$T_{ij} = P(X_t = j | X_{t-1} = i)$$

$O_t$ : на диагонали  $P(e_t | X_t = i)$

Пример:



# Эlegantная запись формул



Forward equation:

$$\mathbf{f}_{1:t+1} = \alpha \mathbf{O}_{t+1} \mathbf{T}^\top \mathbf{f}_{1:t}$$

Backward equation:

$$\mathbf{b}_{k+1:t} = \mathbf{T} \mathbf{O}_{k+1} \mathbf{b}_{k+2:t}$$

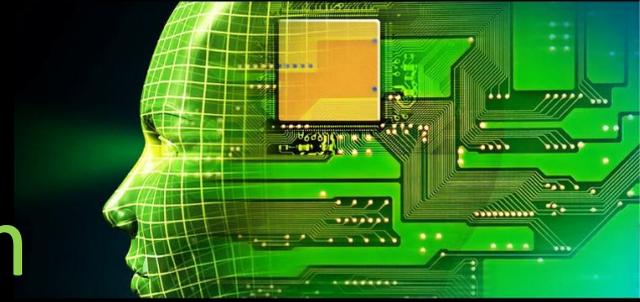
Forward-backward алгоритм

Сложность по времени:  $O(S^2 t)$

Сложность по памяти:  $O(St)$



# Улучшение для forward-backward algorithm



На каждом шаге нужно знать и  $f_{1:k}$  и  $b_{k+1:t}$

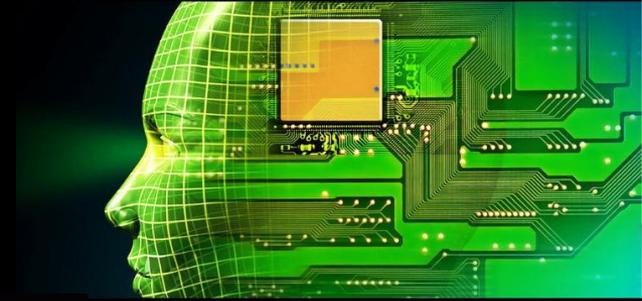
Forward-backward algorithm:

1. Forward filtering от 1 до  $t$   
(не запоминая результатов вычислений)
2. Backward recursion от  $t$  до 1

$$\mathbf{f}_{1:t} = \alpha' (\mathbf{T}^T)^{-1} \mathbf{O}_{t+1}^{-1} \mathbf{f}_{1:t+1}$$



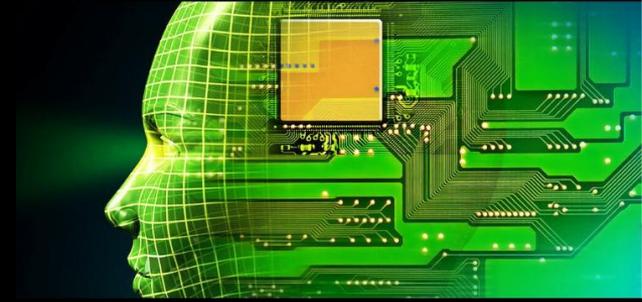
# Kalman Filters



RedDodo.com



# Модель



Обновление состояния:

$$X_{t+\Delta} = X_t + \dot{X}\Delta$$

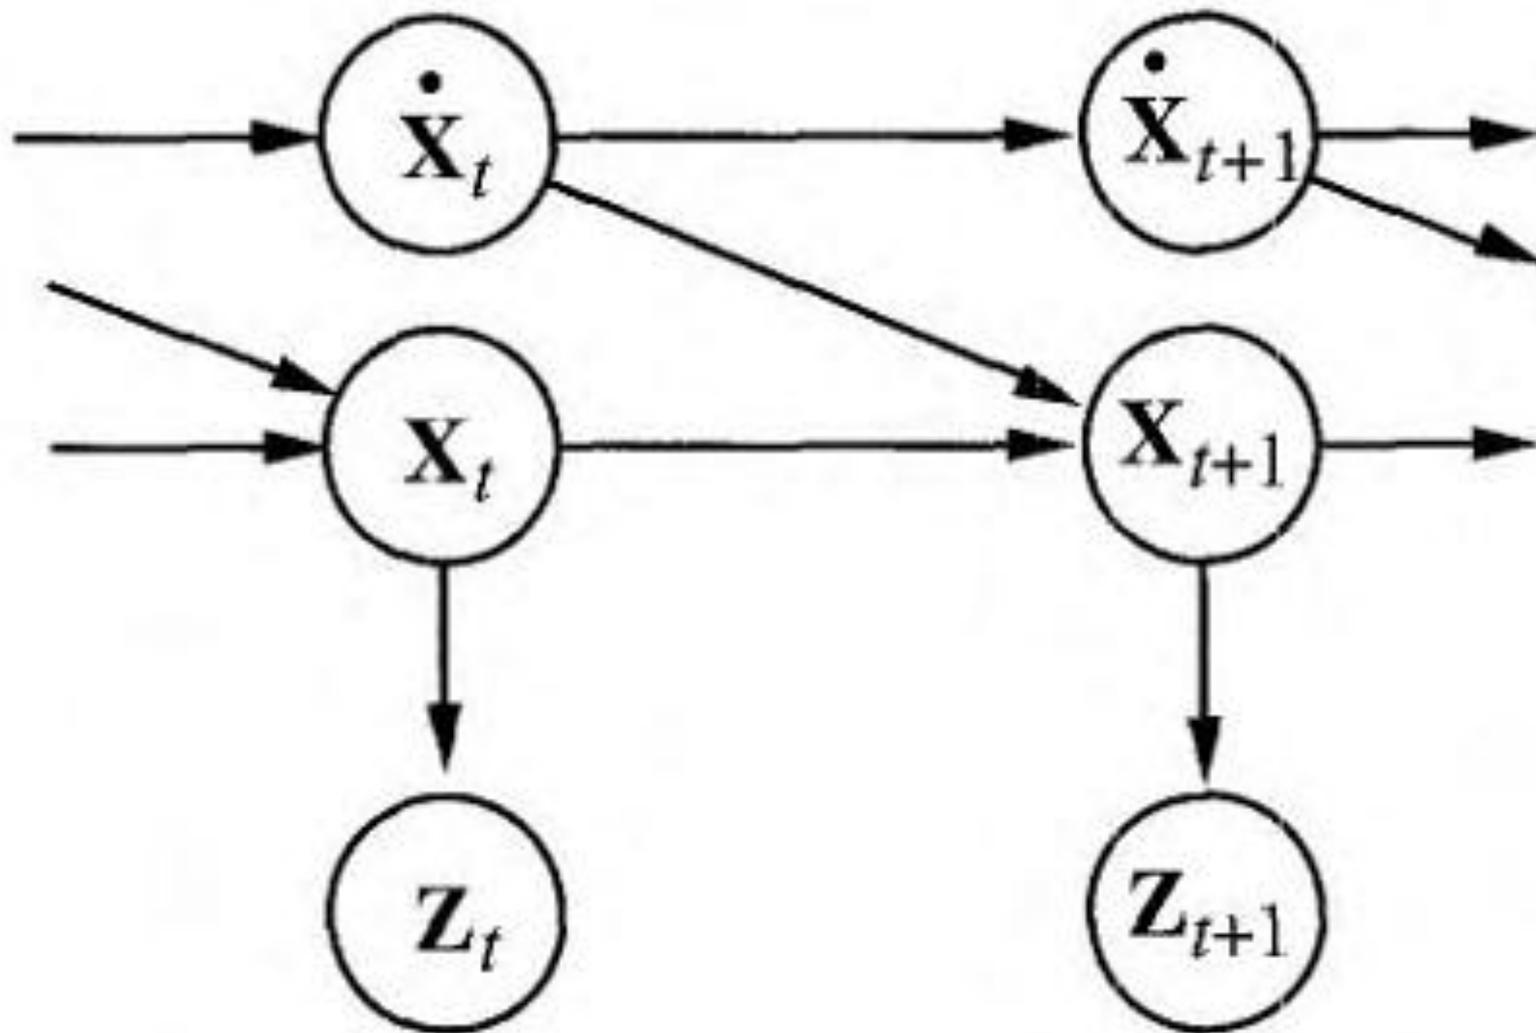
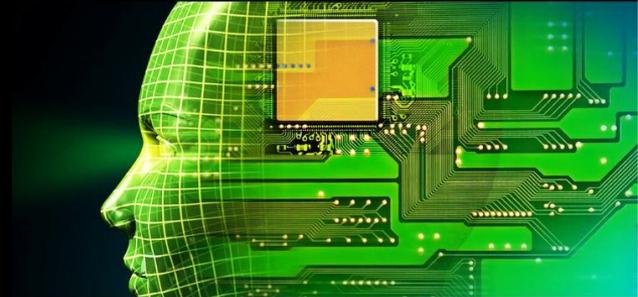
Аддитивный гауссовский шум:

$$X_{t+\Delta} = X_t + \dot{X}\Delta + N(0, \sigma)$$

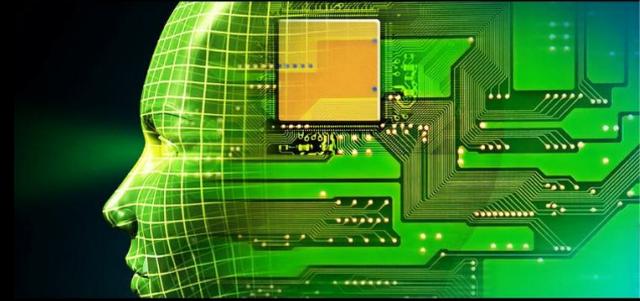
$$\begin{aligned} P(X_{t+\Delta} = x_{t+\Delta} \mid X_t = x_t, \dot{X}_t = \dot{x}_t) &= \\ &= N(x_t + \dot{x}_t\Delta, \sigma)(x_{t+\Delta}) \end{aligned}$$



# Байесовская сеть



# Одномерный случай



Все распределения нормальные:

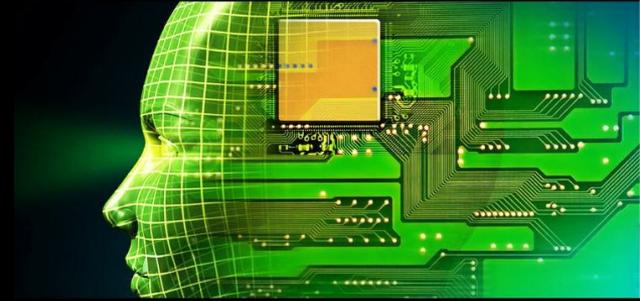
$$P(x_0) = \alpha e^{-\frac{1}{2} \left( \frac{(x_0 - \mu_0)^2}{\sigma_0^2} \right)}$$

$$P(x_{t+1}|x_t) = \alpha e^{-\frac{1}{2} \left( \frac{(x_{t+1} - x_t)^2}{\sigma_x^2} \right)}$$

$$P(z_t|x_t) = \alpha e^{-\frac{1}{2} \left( \frac{(z_t - x_t)^2}{\sigma_z^2} \right)}$$



# Одномерный случай



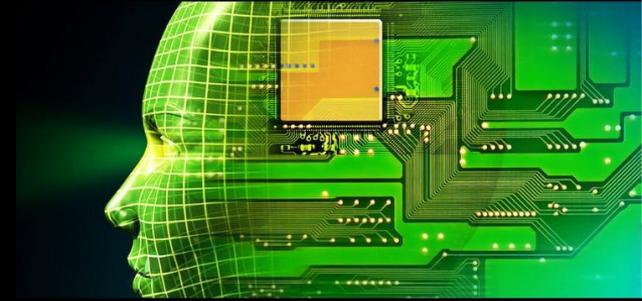
Filtering:

$$\mu_{t+1} = \frac{(\sigma_t^2 + \sigma_x^2)z_{t+1} + \sigma_z^2 \mu_t}{\sigma_t^2 + \sigma_x^2 + \sigma_z^2}$$

$$\sigma_{t+1}^2 = \frac{(\sigma_t^2 + \sigma_x^2)\sigma_z^2}{\sigma_t^2 + \sigma_x^2 + \sigma_z^2}$$



# Общий случай



Все распределения нормальные:

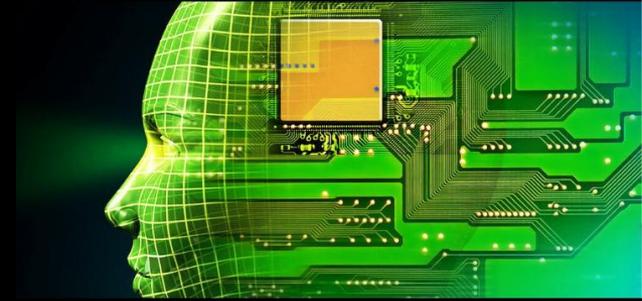
$$\begin{aligned} P(\mathbf{x}_{t+1}|\mathbf{x}_t) &= N(\mathbf{F}\mathbf{x}_t, \Sigma_x)(\mathbf{x}_{t+1}) \\ P(\mathbf{z}_t|\mathbf{x}_t) &= N(\mathbf{H}\mathbf{x}_t, \Sigma_z)(\mathbf{z}_t), \end{aligned}$$

Filtering:

$$\begin{aligned} \mu_{t+1} &= \mathbf{F}\mu_t + \mathbf{K}_{t+1}(\mathbf{z}_{t+1} - \mathbf{H}\mathbf{F}\mu_t) \\ \Sigma_{t+1} &= (\mathbf{I} - \mathbf{K}_{t+1})(\mathbf{F}\Sigma_t\mathbf{F}^\top + \Sigma_x) \end{aligned}$$

$$\mathbf{K}_{t+1} = (\mathbf{F}\Sigma_t\mathbf{F}^\top + \Sigma_x)\mathbf{H}^\top (\mathbf{H}(\mathbf{F}\Sigma_t\mathbf{F}^\top + \Sigma_x)\mathbf{H}^\top + \Sigma_z)^{-1}$$

# Трудности распознавания речи

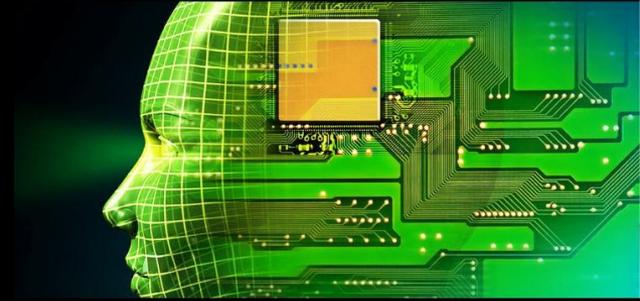


- Шум в данных
  - Фоновый шум
  - Шум от оцифровки
- Одно слово произносится по-разному
- А различные слова могут звучать одинаково
- ...

Проблема распознавания речи –  
проблема вероятностного вывода!



# Общая постановка задачи



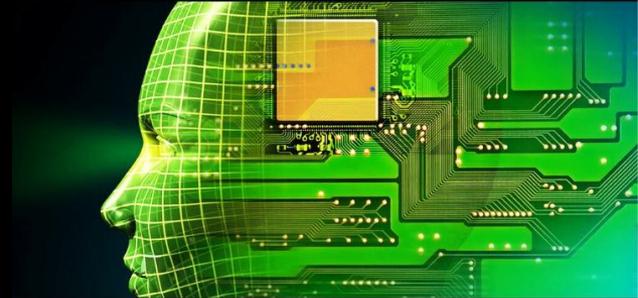
$$\max_{words} P(words | signal)$$

$$P(words | signal) =$$

$$= \underbrace{\alpha P(signal | words)}_{\text{акустическая модель}} \underbrace{P(words)}_{\text{языковая модель}}$$



# Акустическая модель



Частота дискретизации:

- Речь: 8-16 kHz
- Музыка: более 44 kHz

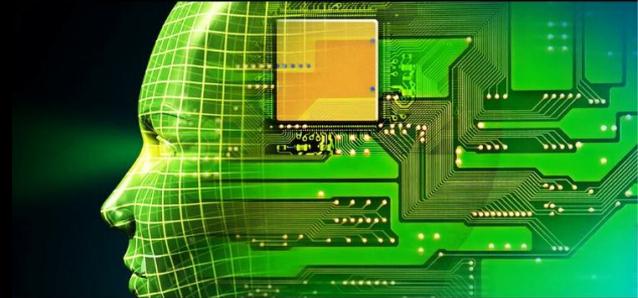
Коэффициент квантования:

8-12 бит

Представление речи: 500 Кб в минуту



# Акустическая модель



Свойства сигнала суммируются по *фреймам*

Длина фрейма:  $\approx 10$  мс

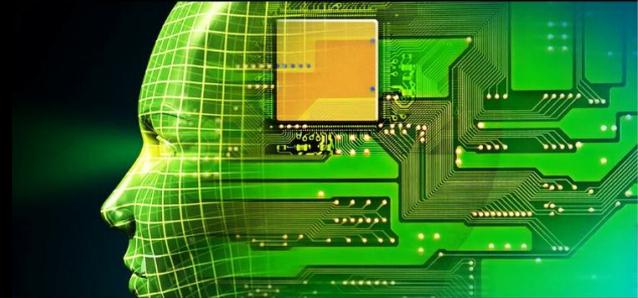
Features:

- Количество энергии в определённом частотном диапазоне
- Общее количество энергии во фрейме
- Отличие от предыдущего фрейма
- ...





# Акустическая модель



Количество возможных фреймов:

$$256^n$$

Проблема: как хранить  $P(\text{features} | \text{phone})$ ?

- Векторное квантование:

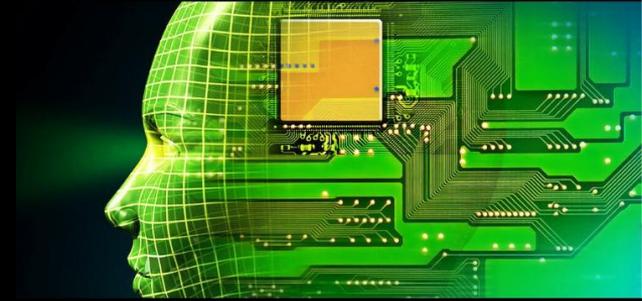
VQ – vector quantization

- Параметризация распределения:

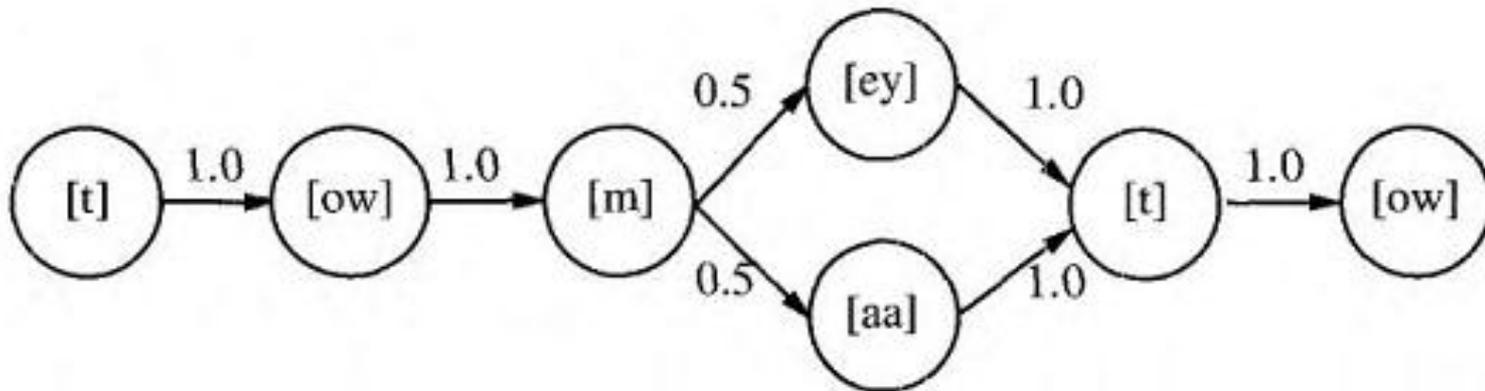
Mixture of Gaussians:  $O(kn^2)$  параметров



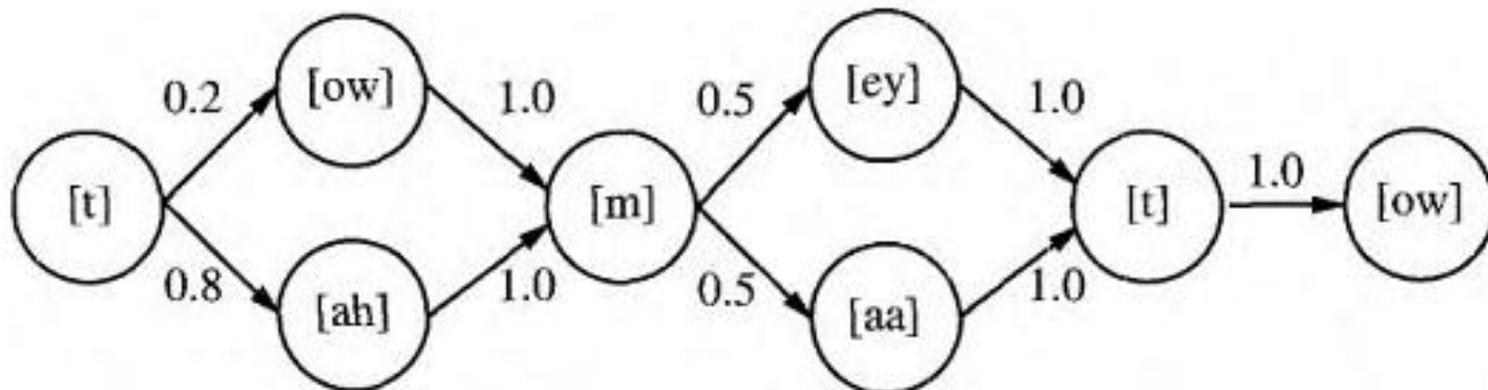
# Модель произношения



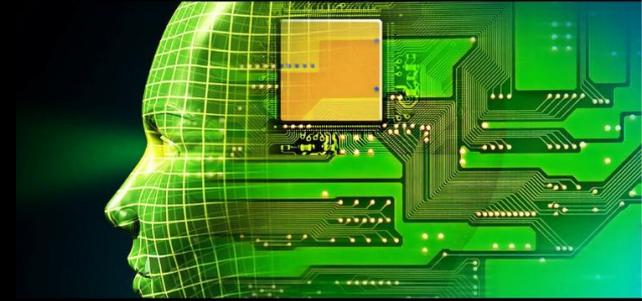
(a) Word model with dialect variation:



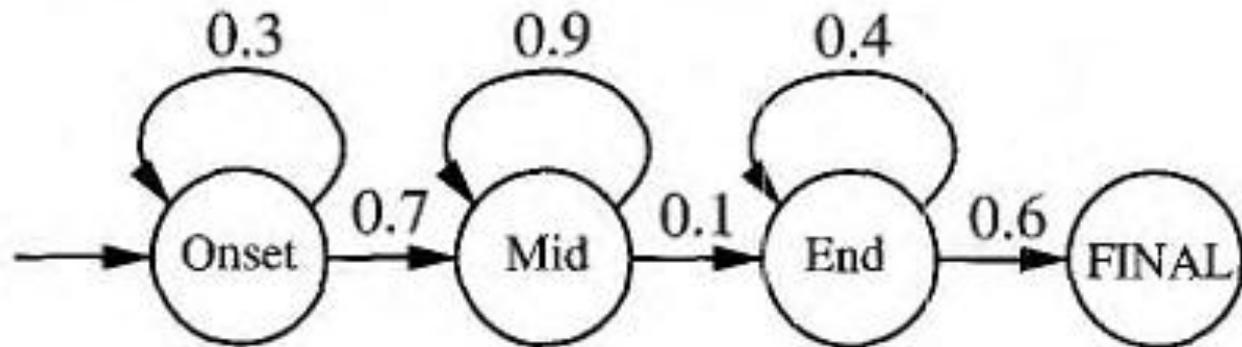
(b) Word model with coarticulation and dialect variations



# Модель фонем



Phone HMM for [m]:

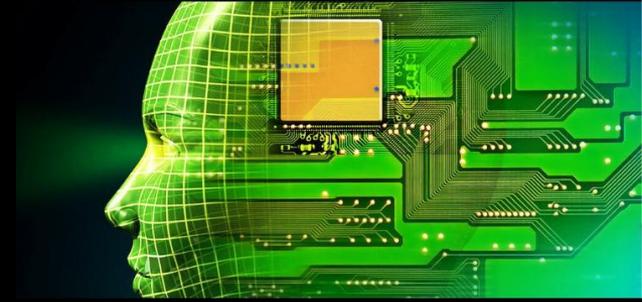


Output probabilities for the phone HMM:

Onset:	Mid:	End:
$C_1: 0.5$	$C_3: 0.2$	$C_4: 0.1$
$C_2: 0.2$	$C_4: 0.7$	$C_6: 0.5$
$C_3: 0.3$	$C_5: 0.1$	$C_7: 0.4$



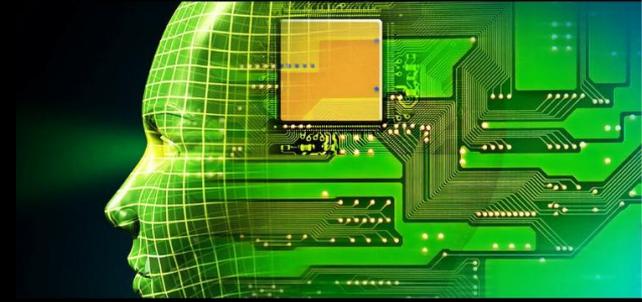
# Распознавание изолированных слов



$$P(\textit{word} \mid e_{1:t}) = \alpha P(e_{1:t} \mid \textit{word})P(\textit{word})$$



# Предложения



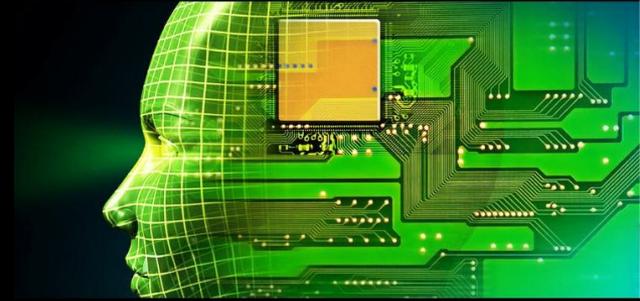
$$P(w_1, \dots, w_n) = \\ = P(w_1)P(w_2 | w_1)P(w_3 | w_1 w_2) \dots P(w_n | w_1 \dots w_{n-1})$$

$$= \prod_{i=1}^n P(w_i | w_1 \dots w_{i-1})$$

Bigram model:

$$P(w_i | w_1 \dots w_{i-1}) = P(w_i | w_{i-1})$$

# Распознавание речи



## 1. Комбинированная НММ

Состояния:  $[m]_{Onset}^{tomato}$

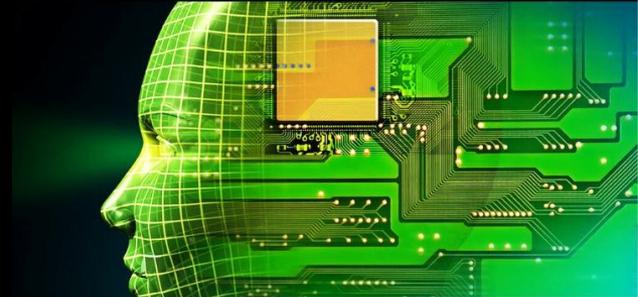
2. Алгоритм Витерби → наиболее вероятная последовательность состояний

3. Извлекаем последовательность слов

Но это *не* наиболее вероятная последовательность слов!



# Декодер $A^*$



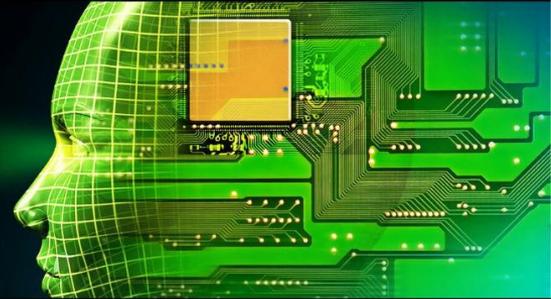
Ориентированный граф:

- Вершина: слово
- Ребро  $(w_1, w_2)$ : слово  $w_2$  может идти после слова  $w_1$
- Стоимость ребра:  $-\log P(w_2|w_1)$

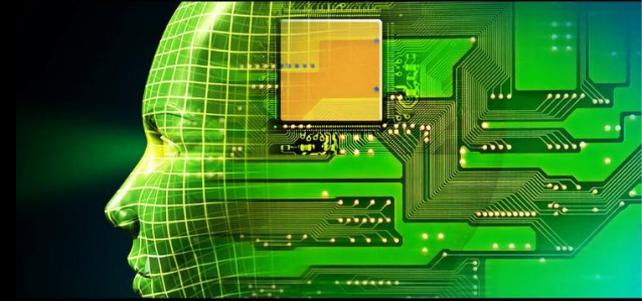
$$Cost(w_1 \cdot \dots \cdot w_n) = \sum_{i=1}^n -\log P(w_i|w_{i-1}) = -\log \prod_{i=1}^n P(w_i|w_{i-1})$$



# Microsoft Speech Recognition



# Контакты



Илья Лысенков

[ilya.lysenkov@gmail.com](mailto:ilya.lysenkov@gmail.com)

<http://twitter.com/ilysenkov>

Клуб Computer Science and Its Applications:

<http://groups.google.com/group/computer-science-and-its-applications>