

# СИСТЕМЫ ОБРАБОТКИ МЕДИАДАННЫХ КЛАССИФИКАЦИЯ. ЛОГИСТИЧЕСКАЯ РЕГРЕССИЯ

**д.т.н., доцент Вашкевич М. И.**

**[vashkevich@bsuir.by](mailto:vashkevich@bsuir.by)**



Белорусский государственный университет  
информатики и радиоэлектроники  
Кафедра электронных вычислительных средств

# Задача классификации

Пример: классификация ирисов (Фишер, 1940-е)

150 растений (50 каждого сорта)

- сорта: щетинистый, разноцветный, виргинский
- длина и ширина чашелистика (в см)
- длина и ширина лепестка (в см)



Ирис щетинистый (*setosa*)

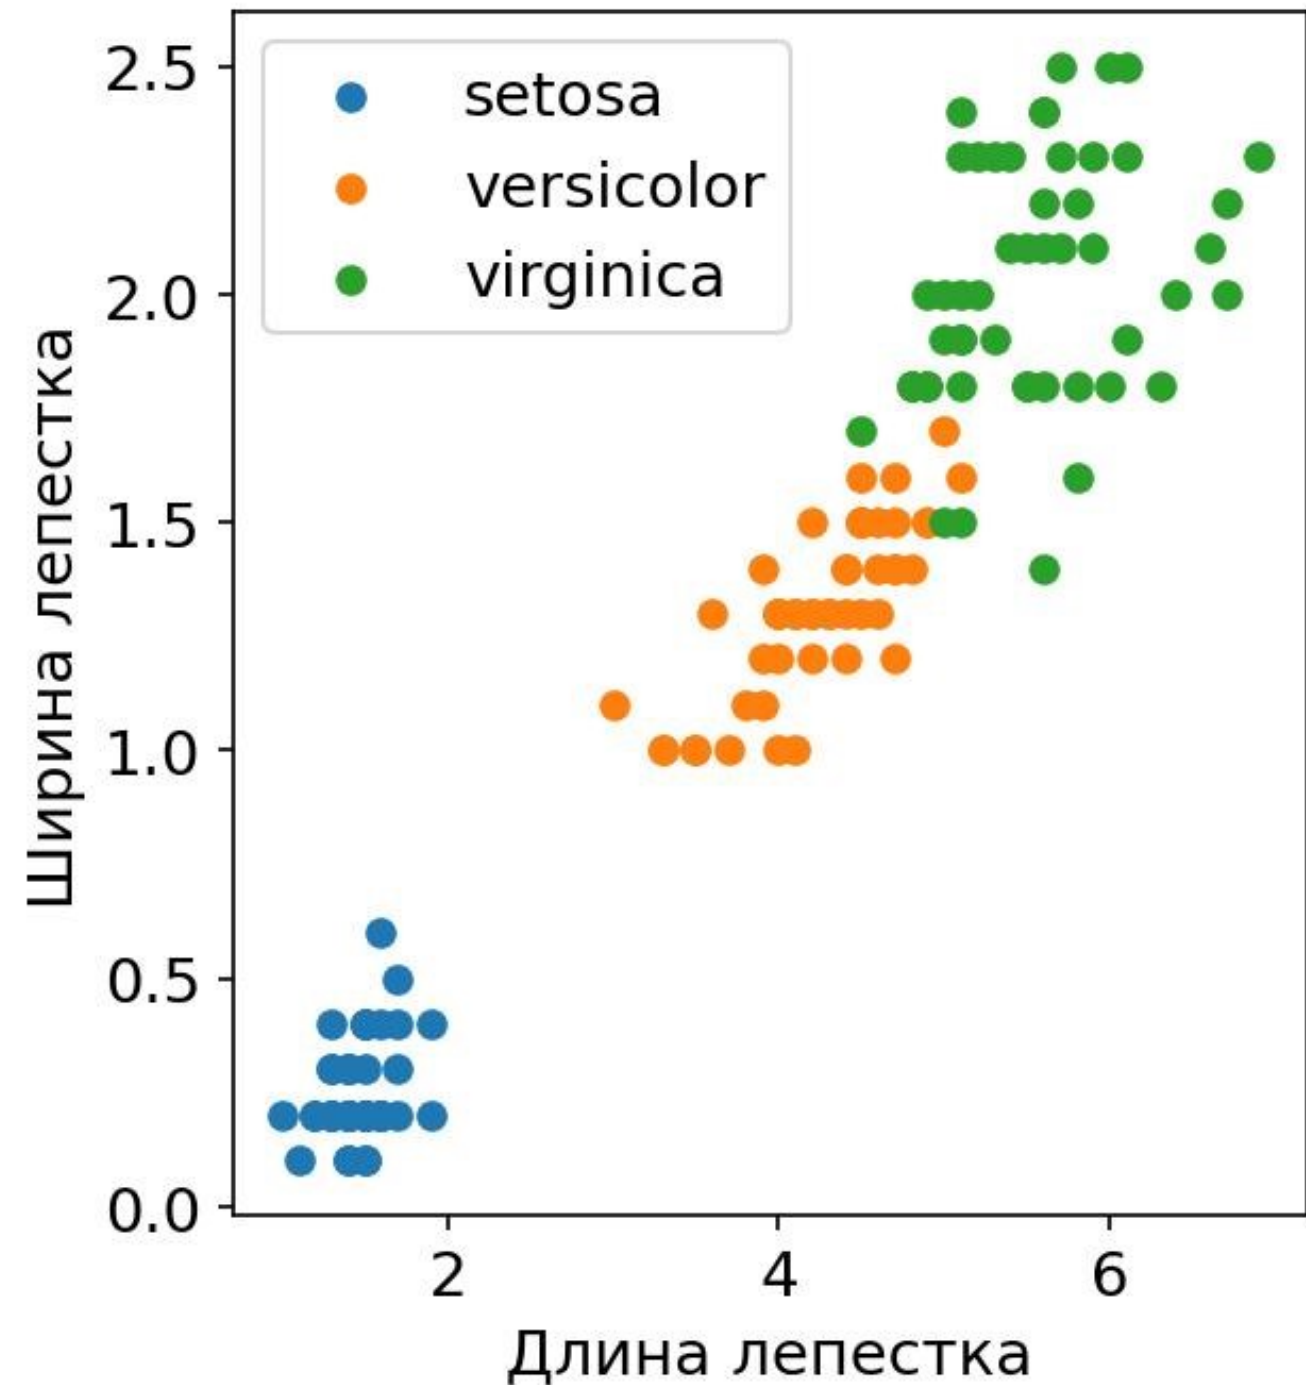
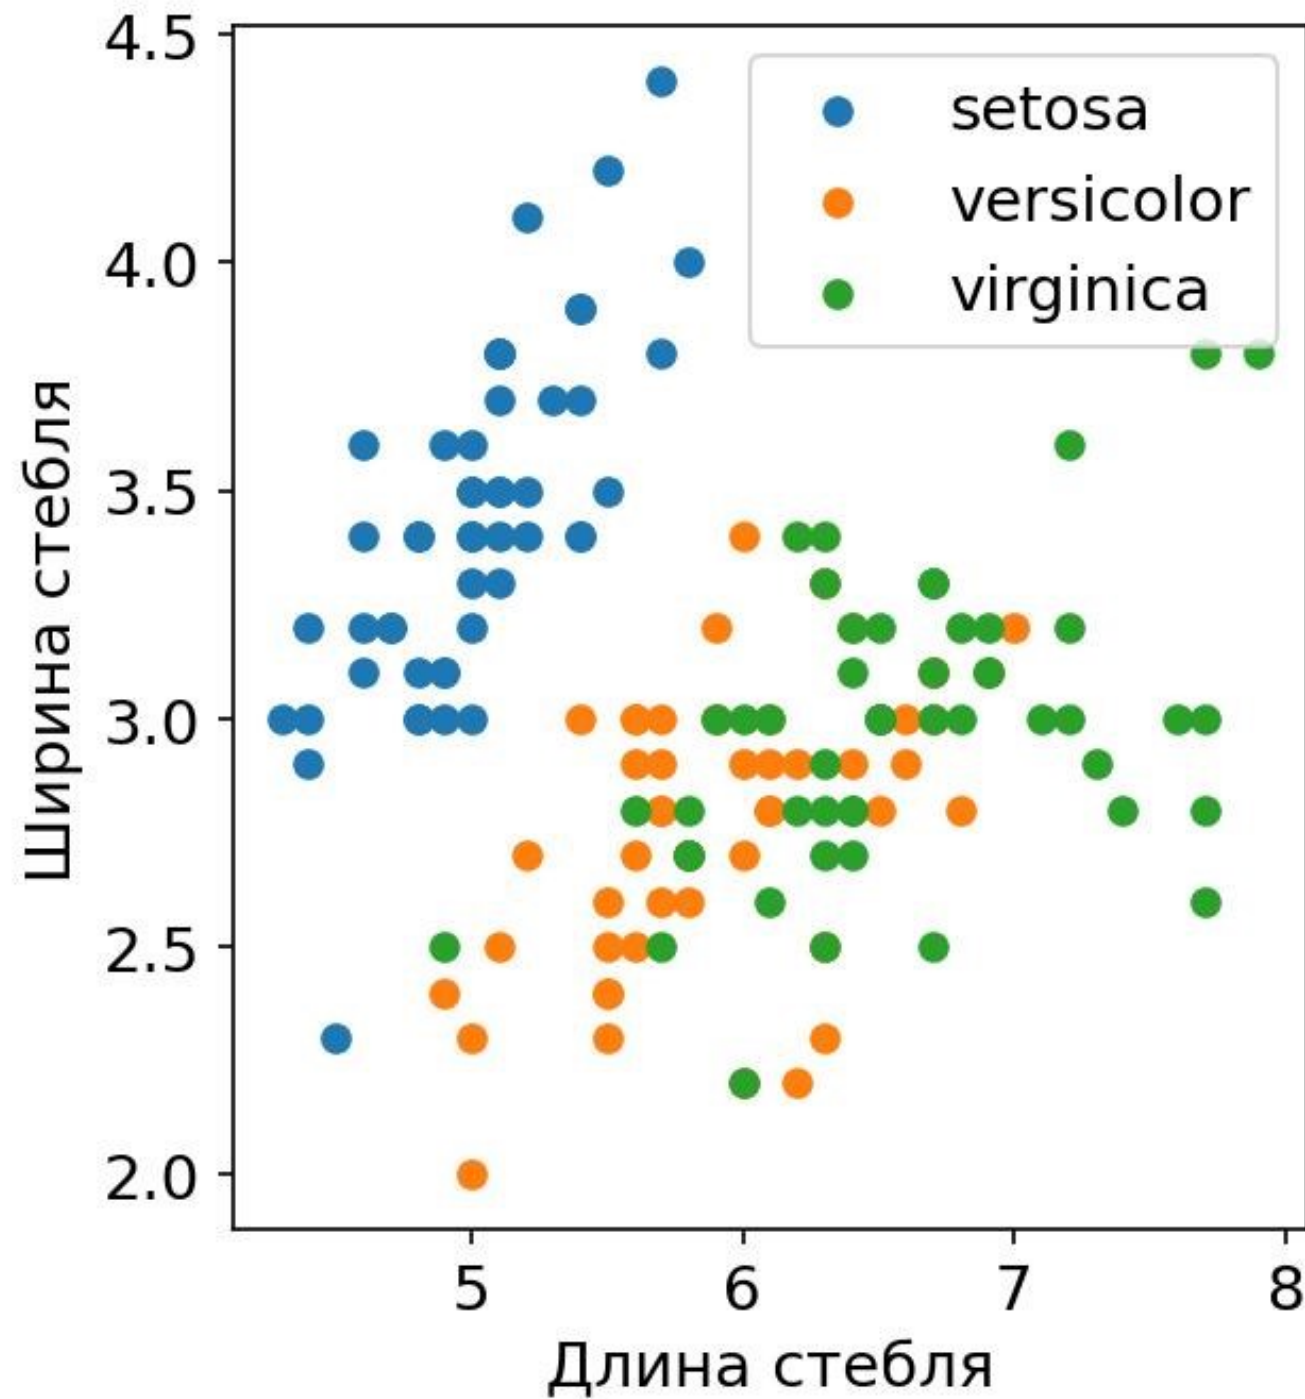


Ирис разноцветный (*versicolor*)



Ирис виргинский (*virginica*)

# Задача классификации



# Формальная постановка задачи классификации

- $X_1, X_2, \dots, X_p$  – *предикторы* (или *описательные признаки*).

Все предикторы можно объединить в один вектор

$$X := (X_1, X_2, \dots, X_p)$$

- $Y$  – случайная величина, называемая *целевой переменной*

# Формальная постановка задачи классификации

- $X_1, X_2, \dots, X_p$  – **предикторы** (или **описательные признаки**).

Все предикторы можно объединить в один вектор

$$X := (X_1, X_2, \dots, X_p)$$

- $Y$  – случайная величина, называемая **целевой переменной**
- Пусть  $\mathcal{Y}$  – область значений  $Y$ . В задаче классификации  $\mathcal{Y}$  – это конечное множество классов (пространство меток классов). Иногда говорят, что  $Y$  относится к **категориальному** типу данных.
- $\mathcal{D} \subset \mathcal{P}(X \times \mathcal{Y})$  – множество примеров из неизвестного совместного распределения  $p(X, Y)$  входов и выходов, которое называется **данными**.
- $\mathcal{D}$  обычно записывается списком

$$\mathcal{D} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$$

# Формальная постановка задачи классификации

- Задача классификации – предсказать  $Y$  на основе  $X$ .

$$f: X \rightarrow Y$$

- $f(x)$  иногда называются *помечающей функцией*.

# Формальная постановка задачи классификации

- Задача классификации – предсказать  $Y$  на основе  $X$ .

$$f: X \rightarrow Y$$

- $f(x)$  иногда называются *помечающей функцией*.
- Под обучением классификатора понимается построение функции  $\hat{f}(x)$ , которая как можно лучше аппроксимирует  $f(x)$ .



# Формальная постановка задачи классификации

- Задача классификации – предсказать  $Y$  на основе  $X$ .

$$f: X \rightarrow Y$$

- $f(x)$  иногда называются *помечающей функцией*.

- Под обучением классификатора понимается построение функции  $\hat{f}(x)$ , которая как можно лучше аппроксимирует  $f(x)$ .

- Другими словами, необходимо оценить функцию

$$f(x) := E\{Y|X = x\} = \int y \cdot p(y|x) dy$$

на основе имеющихся данных  $\mathcal{D}$ .



# Бинарная классификация






В простейшем случае есть всего два класса, которые называют **положительным** и **отрицательным**,  $\oplus$  и  $\ominus$  или  $+1$  и  $-1$ .

Двухклассовую классификацию называют **бинарной классификацией**.









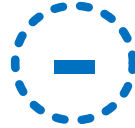

## Примеры

- Фильтрация спама
- Медицинская диагностика ( $\oplus$  – наличие заболевания)
- Обнаружение мошенничества с кредитными картами.



# Бинарная классификация

<b>Данные</b>	$x_1$	$x_2$	$x_3$	$x_4$	...	$x_N$
<b>Метки</b>					...	
<b>Предсказание модели</b>						





# Бинарная классификация

Данные	$x_1$	$x_2$	$x_3$	$x_4$	...	$x_N$
Метки $y_i$					...	
Предсказание модели $\hat{y}_i$					...	







# Результаты бинарной классификации

Метка класса	Предсказание модели	Тип результата	Название результата
		<b>TP</b> (True Positive)	Истинно-положительный

# Результаты бинарной классификации

Метка класса	Предсказание модели	Тип результата	Название результата
		<b>TP</b> (True Positive)	Истинно-положительный
		<b>FN</b> (False Negative)	Ложно-отрицательный

# Результаты бинарной классификации










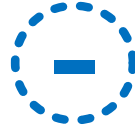

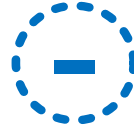
Метка класса	Предсказание модели	Тип результата	Название результата
		<b>TP</b> (True Positive)	Истинно-положительный
		<b>FN</b> (False Negative)	Ложно-отрицательный
		<b>TN</b> (True Negative)	Истинно-отрицательный

# Результаты бинарной классификации













Метка класса	Предсказание модели	Тип результата	Название результата
		<b>TP</b> (True Positive)	Истинно-положительный
		<b>FN</b> (False Negative)	Ложно-отрицательный
		<b>TN</b> (True Negative)	Истинно-отрицательный
		<b>FP</b> (False Positive)	Ложно-положительный















# Результаты бинарной классификации: пример

Данные	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
Метки $y_i$						
Предсказание модели $\hat{y}_i$						
Тип результата	?	?	?	?	?	?













# Результаты бинарной классификации: пример

Данные	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
Метки $y_i$						
Предсказание модели $\hat{y}_i$						
Тип результата	ТР	ТР	?	?	?	?










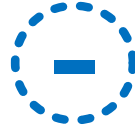

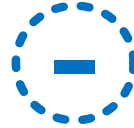
# Результаты бинарной классификации: пример

Данные	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
Метки $y_i$						
Предсказание модели $\hat{y}_i$						
Тип результата	TP	TP	TN	?	?	TN

# Результаты бинарной классификации: пример





Данные	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
Метки $y_i$						
Предсказание модели $\hat{y}_i$						
Тип результата	TP	TP	TN	FN	?	TN

# Результаты бинарной классификации: пример

Данные	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$
Метки $y_i$						
Предсказание модели $\hat{y}_i$						
Тип результата	TP	TP	TN	FN	FP	TN













# Матрица неточностей

*Confusion matrix* – матрица неточностей (или матрица спутывания).



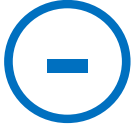
		Предсказанные метки		
				
Истинные метки класса		TP	FN	$TP + FN$
		FP	TN	$FP + TN$
		$TP + FP$	$FN + TN$	$TP + TN + FP + FN$

В последнем столбце и в последней строке находятся **маргиналы** – суммы элементов в соответствующем столбце и строке.

# Матрица неточностей: пример

Метки $y_i$						
Предсказание модели $\hat{y}_i$						
Тип	TP	TP	TN	FN	FP	TN

## Матрица неточностей

		Предсказанные метки		
				
Истинные метки класса		2	1	3
		1	2	3
		3	3	6



# Правильность





**Правильность** (*accuracy*) – доля правильно классифицированных тестовых примеров.

$$Acc = \frac{TP + TN}{TP + FP + TN + FN}$$

# Правильность

**Правильность** (*accuracy*) – доля правильно классифицированных тестовых примеров.

$$Acc = \frac{TP + TN}{TP + FP + TN + FN}$$





		Предсказанные метки		
				
Истинные метки класса		TP = 2	FN = 1	3
		FP = 1	TN = 2	3
		3	3	6

$Acc = ?$

# Правильность

**Правильность** (*accuracy*) – доля правильно классифицированных тестовых примеров.

$$Acc = \frac{TP + TN}{TP + FP + TN + FN}$$

		Предсказанные метки		
				
Истинные метки класса		TP = 2	FN = 1	3
		FP = 1	TN = 2	3
		3	3	6

$$Acc = \frac{2 + 2}{6} = \frac{2}{3} \approx 66\%$$

# ЛОГИСТИЧЕСКАЯ РЕГРЕССИЯ

# Логистический сигмоид

Свойства логистической функции:


$$g(z) = \frac{e^z}{1 + e^z} = \frac{1}{1 + e^{-z}}$$

- значения в диапазоне от 0 до 1;
- стремится к 1 при  $z \rightarrow \infty$ ;
- стремится к 0 при  $z \rightarrow -\infty$ ;
- гладкая и симметричная относительно точки  $(0, 0.5)$
- Симметрия:

$$g(-z) = 1 - g(z).$$

- Производная:

$$\frac{dg}{dx} = g(x)(1 - g(x)).$$




# Логит-функция

Свойства логит-функции:

$$\text{logit}(x) = \log\left(\frac{x}{1-x}\right)$$

- определена в диапазоне от 0 до 1;
  - стремится к  $\infty$  при  $x \rightarrow 1$ ;
  - стремится к  $-\infty$  при  $x \rightarrow 0$ ;
  - гладкая и симметричная относительно точки  $(0, 0.5)$
  - обратная к логистической функции
- $$\text{logit}(g(x)) = x$$



# Модель логистической регрессии

Целевая переменная  $y$  является бинарной, т.е.  $\mathcal{Y} := \{0,1\}$ .

Можно ли использовать модель линейной регрессии

$$y = \mathbf{w}^T \mathbf{x}$$

для классификации?



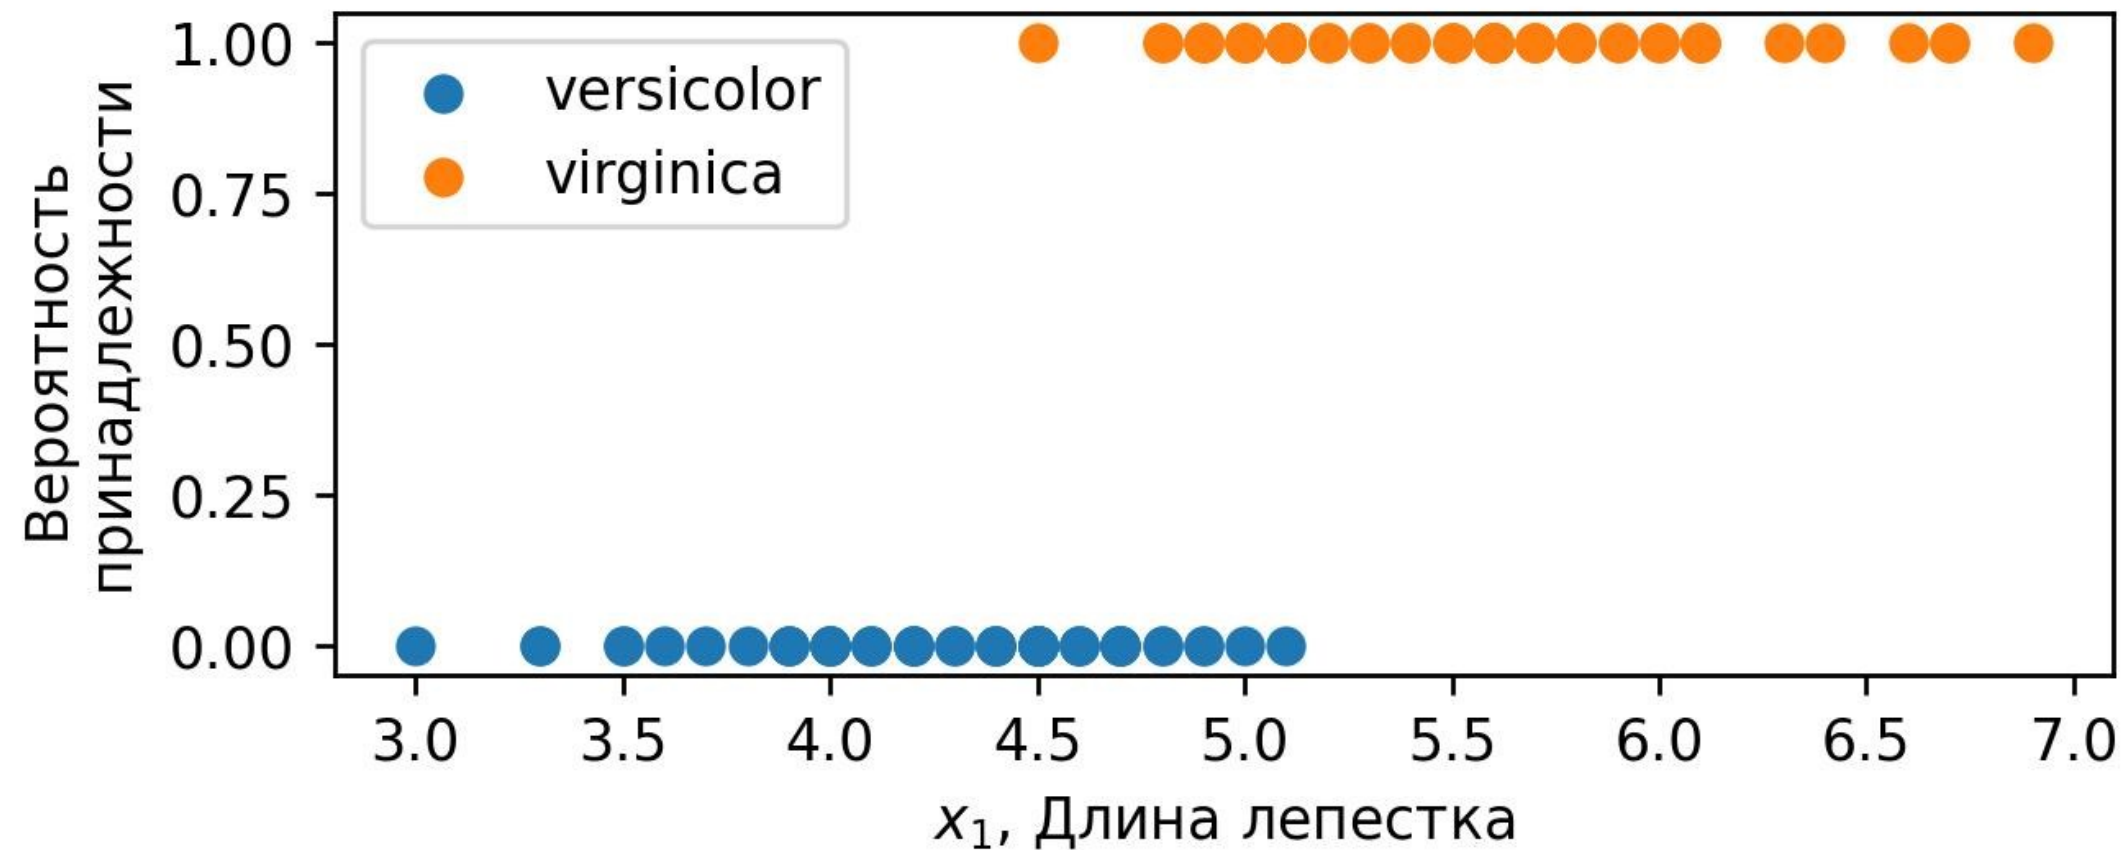
# Модель логистической регрессии

Целевая переменная  $y$  является бинарной, т.е.  $\mathcal{Y} := \{0,1\}$ .

Можно ли использовать модель линейной регрессии

$$y = \mathbf{w}^T \mathbf{x}$$

для классификации?



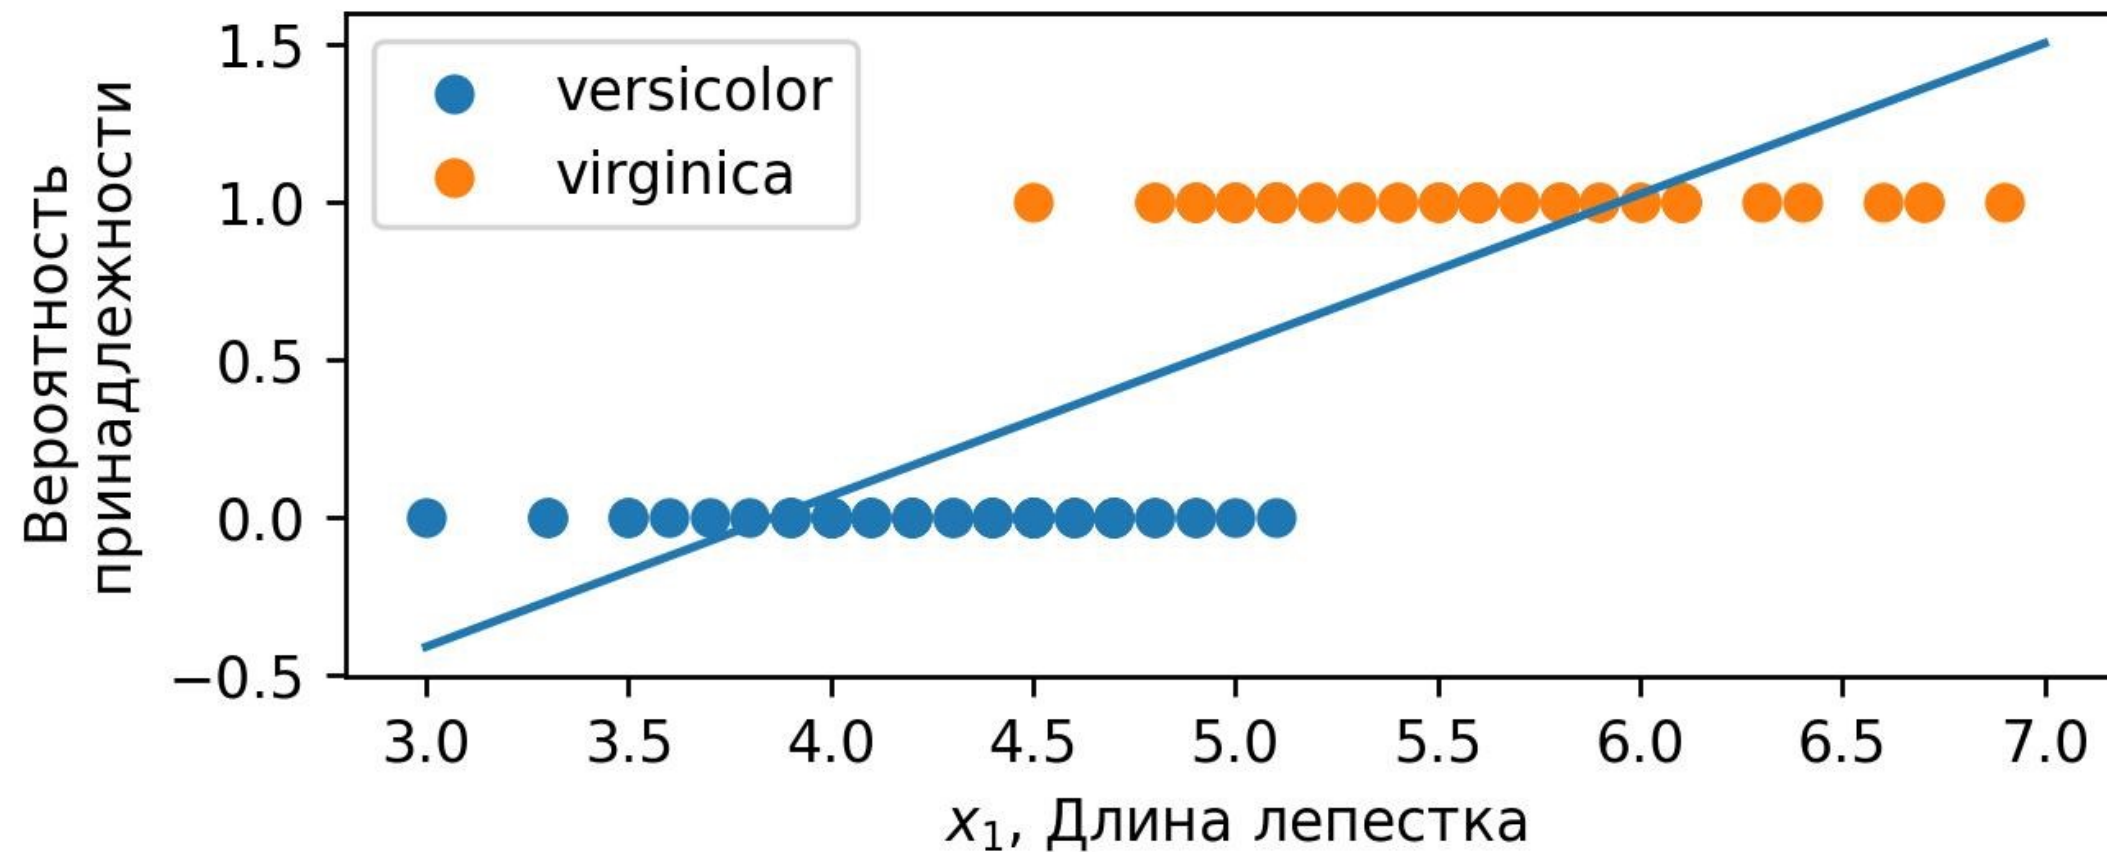
# Модель логистической регрессии

Целевая переменная  $y$  является бинарной, т.е.  $\mathcal{Y} := \{0,1\}$ .

Можно ли использовать модель линейной регрессии

$$y = \mathbf{w}^T \mathbf{x}$$


для классификации?



# Модель логистической регрессии

- Линейная регрессия не подходит для предсказания вероятностей, поскольку предсказываемые ею значения принципиально не ограничены.

## Применение линейной регрессии для бинарной классификации



# Модель логистической регрессии

- Вместо предсказания  $y$  напрямую, можно предсказывать

$P(y = 1 | \mathbf{x})$  – вероятность, что  $y = 1$  при условии, что наблюдается  $\mathbf{x}$ .

# Модель логистической регрессии

- Вместо предсказания  $y$  напрямую, можно предсказывать  $P(y = 1 | \mathbf{x})$  – вероятность, что  $y = 1$  при условии, что наблюдается  $\mathbf{x}$ .
- Для моделирования  $P(y = 1 | \mathbf{x})$  необходима функция, которая всегда возвращает значения из интервала от 0 до 1. В логистической регрессии для этого применяют логистическую функцию (😊):

$$P(y = 1 | \mathbf{x}) = p(\mathbf{x}) = g(\mathbf{w}^T \mathbf{x}) = \frac{1}{1 + \exp(-\mathbf{w}^T \mathbf{x})}$$

# Интерпретация логистической регрессии

- Если преобразовать

$$p(\mathbf{x}) = \frac{1}{1 + \exp(-\mathbf{w}^T \mathbf{x})},$$

то можно получить выражение:

$$\frac{p(\mathbf{x})}{1 - p(\mathbf{x})} = \exp(-\mathbf{w}^T \mathbf{x}).$$

- Величина  $p(\mathbf{x})/(1 - p(\mathbf{x}))$  называется **риск события** и принимает значения от 0 до  $\infty$ .

# Интерпретация логистической регрессии

- Если преобразовать

$$p(\mathbf{x}) = \frac{1}{1 + \exp(-\mathbf{w}^T \mathbf{x})},$$

то можно получить выражение:


$$\frac{p(\mathbf{x})}{1 - p(\mathbf{x})} = \exp(-\mathbf{w}^T \mathbf{x}).$$

- Величина  $p(\mathbf{x})/(1 - p(\mathbf{x}))$  называется **риск события** и принимает значения от 0 до  $\infty$ .
- Например, если вероятность события равна  $p(\mathbf{x}) = 0,2$ , то риск наступления этого события  $\frac{1}{4}$ , поскольку  $\frac{0,2}{1-0,2} = 1/4$ .
- Какой риск, если  $p(\mathbf{x}) = 0,9$ ?

# Модель логистической регрессии

- Рассмотрим, как изменение  $\mathbf{w}$  влияют на вид функции
- Пример одномерных данных:

$$y = g(w_1x + w_0) = \frac{1}{1 + \exp(-(w_1x + w_0))}.$$







# Модель логистической регрессии

- Рассмотрим, как изменение  $w$  влияют на вид функции
- Пример одномерных данных:




$$y = g(w_1x + w_0) = \frac{1}{1 + \exp(-(w_1x + w_0))}.$$



# Модель логистической регрессии

- Рассмотрим, как изменение  $w$  влияют на вид функции
- Пример одномерных данных:

$$y = g(w_1x + w_0) = \frac{1}{1 + \exp(-(w_1x + w_0))}$$



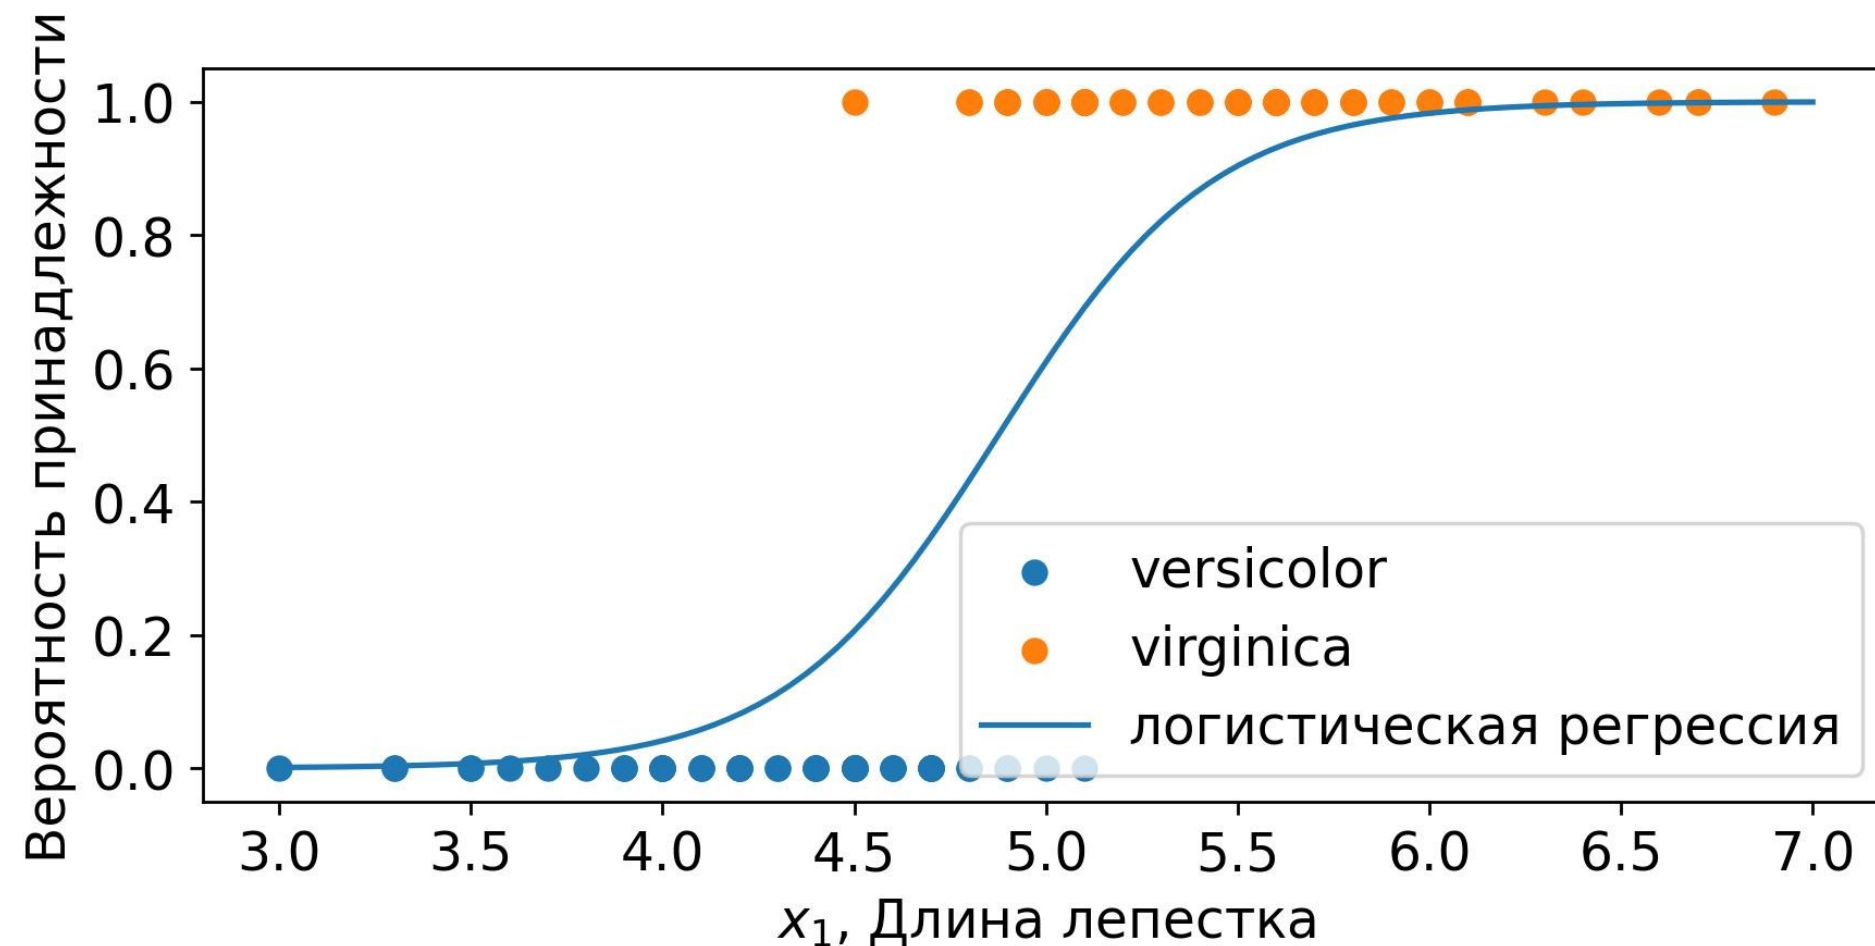
# Модель логистической регрессии

- Логистическая регрессия:

$$P(y = 1|\mathbf{x}) = g(\mathbf{w}^T \mathbf{x}) = \frac{1}{1 + \exp(-\mathbf{w}^T \mathbf{x})}$$

- Логистическая функция всегда порождает S-образную кривую.

## Применение логистической регрессии для бинарной классификации



# Вероятностная интерпретация

- Поскольку мы интерпретируем  $g(\mathbf{w}^T \mathbf{x})$  как вероятность  $P(y = 1 | \mathbf{x})$ , то, используя свойства вероятностей можно записать, что


$$P(y = 1 | \mathbf{x}) + P(y = 0 | \mathbf{x}) = 1.$$

- Таким образом,


$$P(y = 0 | \mathbf{x}) = 1 - P(y = 1 | \mathbf{x}) = \frac{\exp(-\mathbf{w}^T \mathbf{x})}{1 + \exp(-\mathbf{w}^T \mathbf{x})}.$$

# Решающая граница

- Как выглядит решающая граница логистической регрессии?
- $P(y = 0|\mathbf{x}) = P(y = 1|\mathbf{x}) = 0.5$
- $P(y = 1|\mathbf{x}) = g(\mathbf{w}^T \mathbf{x} + w_0) = 0.5$ , где  $g(z) = \frac{1}{1 + \exp(-z)}$
- Решающая граница  $\mathbf{w}^T \mathbf{x} + w_0 = 0$
- У логистической регрессии **линейная решающая граница**.



# Сравнение линейной и логистической регрессии



- Логистическая регрессия менее подвержена выбросам.

# Обучение логистической регрессии

- На входе имеются  $p$ -мерные вектора признаков  $\mathbf{x} \in \mathbb{R}^p$
- Требуется обучить вектор коэффициентов  $\mathbf{w} = [w_0, w_1, \dots, w_p]$
- Логистическая регрессия является вероятностной моделью
- Можно воспользоваться **методом максимального правдоподобия**



# Условное правдоподобие

- Целевые переменные  $y^{(i)} \in \{0,1\}$ . Вероятность появления набора данных  $\mathcal{D} = \{(\mathbf{x}^{(1)}, y^{(1)}), (\mathbf{x}^{(2)}, y^{(2)}), \dots, (\mathbf{x}^{(n)}, y^{(n)})\}$  можно описать **функцией правдоподобия**

$$CL(\mathbf{w}) = \prod_{i=1}^n p(y^{(i)} | \mathbf{x}^{(i)}; \mathbf{w}).$$

- Мы можем переписать каждую отдельную вероятность в следующем виде

$$\begin{aligned} p(y^{(i)} | \mathbf{x}^{(i)}; \mathbf{w}) &= p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})^{y^{(i)}} \times p(y = 0 | \mathbf{x}^{(i)}; \mathbf{w})^{1-y^{(i)}} \\ &= p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})^{y^{(i)}} \times \left(1 - p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})\right)^{1-y^{(i)}} \end{aligned}$$

- Мы можем обучить модель максимизировав правдоподобие:

$$\max_{\mathbf{w}} CL(\mathbf{w}) = \max_{\mathbf{w}} \prod_{i=1}^n p(y^{(i)} | \mathbf{x}^{(i)}; \mathbf{w})$$

- Проще работать с логарифмом функции правдоподобия  $\log CL(\mathbf{w})$ .



# Функция потерь (loss function)

$$\begin{aligned} CL(\mathbf{w}) &= \prod_{i=1}^n p(y^{(i)} | \mathbf{x}^{(i)}; \mathbf{w}) \\ &= \prod_{i=1}^n p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})^{y^{(i)}} \times \left(1 - p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})\right)^{1-y^{(i)}}. \end{aligned}$$

- Обычно задачу максимизации заменяют задачей минимизации, можно записать следующую **функцию потерь**:

$$\begin{aligned} NLL(\mathbf{w}) &= -\log CL(\mathbf{w}) \\ &= -\log \prod_{i=1}^n p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})^{y^{(i)}} \times \left(1 - p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})\right)^{1-y^{(i)}} \\ &= -\sum_{i=1}^n y^{(i)} \log p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w}) - \sum_{i=1}^n (1 - y^{(i)}) \log \left(1 - p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})\right) \\ &= -\sum_{i=1}^n y^{(i)} \log p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w}) + (1 - y^{(i)}) \log \left(1 - p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w})\right). \end{aligned}$$

# Градиентный спуск

$$\min_{\mathbf{w}} NLL(\mathbf{w})$$

- Градиентный спуск: на каждой итерации вычисляется направление наибольшего убывания и выполняется движение в этом направлении с шагом  $\eta$ :

$$\mathbf{w}_t = \mathbf{w}_{t-1} - \eta \frac{\partial NLL}{\partial \mathbf{w}},$$

- Какова зависимость от  $\mathbf{w}$ ?

$$p(y = 1 | \mathbf{x}; \mathbf{w}) = \frac{1}{1 + \exp(-\mathbf{w}^T \mathbf{x} + w_0)}$$

- Можно показать, что

$$\frac{\partial NLL}{\partial \mathbf{w}} = \sum_{i=1}^n (p(y = 1 | \mathbf{x}^{(i)}; \mathbf{w}) - y_i) \mathbf{x}^{(i)}$$

# Выводы

## Преимущества логистической регрессии

- Легко расширяется на многоклассовую классификацию;
- Вероятностная интерпретация на предсказание класса;
- Высокая скорость обучения;
- Быстрая классификация (быстрый вывод, inference);
- Хорошая точность на множестве наборов данных;
- Устойчивость к переобучению;
- Значение коэффициентов может быть интерпретировано, как индикатор важности признака;

## Менее хорошее свойство

- Линейная решающая граница (слишком просто для сложных задач).