

# МАТЕМАТИЧЕСКИЕ ОСНОВЫ ТЕОРИИ ПРОГНОЗИРОВАНИЯ

Лектор

Сенько Олег Валентинович

Лекция I

Задачи диагностики и прогнозирования некоторой величины  $Y$   
по доступным значениям переменных  $X_1, \dots, X_n$  часто  
возникают в различных областях человеческой деятельности:

- постановка медицинского диагноза или результатов лечения по совокупности клинических и лабораторных показателей;
- прогноз свойств ещё не синтезированного химического соединения по его молекулярной формуле;
- диагностика хода технологического процесса;
- Диагностика состояния технического оборудования;
- прогноз финансовых индикаторов;
- и многие другие задачи

# Типы прогнозируемых величин

Прогнозируемая величина  $Y$  может иметь различную природу:

- принимать значения из отрезка непрерывной оси;
- принимать значения из конечного множества;
- являться кривой, описывающей вероятность возникновения некоторого критического события до различных моментов времени.
- Задачи, в которых прогнозируемая величина принимает значения из множества, содержащего несколько элементов принято называть задачей распознавания, Например, к задачам распознавания относятся задачи прогнозирования категориальных переменных.

# Генеральная совокупность

Множество объектов, которые могут возникать в рамках рассматриваемой задачи, называется генеральной совокупностью  $\Omega$

Обычно генеральная совокупность рассматривается как множество элементарных событий, на котором заданы  $\sigma$ -алгебра событий  $\Sigma$  и вероятностная мера  $P$ . То есть генеральная совокупность рассматривается как вероятностное пространство  $\langle \Omega, \Sigma, P \rangle$

Значение  $Y$  для некоторых объектов  $\Omega$  может оказаться неизвестным. Однако данное значение может быть восстановлено по вектору известных значений переменных  $X_1, \dots, X_n$

# Методы, основанные на обучении по прецедентам

В случаях, когда существует выборка прецедентов, для которых известны значения прогнозируемой величины  $Y$  и переменных  $X_1, \dots, X_n$  для решения задач прогнозирования могут быть использованы методы, основанные на обучении по прецедентам. Выборку прецедентов принято называть

## Обучающей выборкой

Обучающая выборка имеет вид  $\tilde{S}_t = \{(y_1, \mathbf{x}_1), \dots, (y_m, \mathbf{x}_m)\}$ ,  
где  $y_j$  - значение переменной  $Y$  для объекта  $s_j$  ;  
 $\mathbf{x}_j$  - значение вектора переменных  $X_1, \dots, X_n$  для объекта  $s_j$  ;  
 $j = 1, \dots, m$  ;  
 $m$  - число объектов в  $\tilde{S}_t$  ;

# Обучающая выборка

Обычно предполагается, что обучающая выборка может рассматриваться как независимая, выборка объектов из  $\Omega$ .

Иными словами предполагается, что  $\tilde{S}_t$  является элементом

декартова произведения  $\Omega_m = \Omega \times \dots \times \Omega$ . При этом

предполагается, что на  $\Omega_m$  задана  $\sigma$ -алгебра  $\Sigma_m$ ,

содержащая всевозможные

декартовы произведения вида  $\mathbf{a}_1 \times \dots \times \mathbf{a}_m$ , где  $\mathbf{a}_i \in \Sigma, i = 1, \dots, m$ , и

вероятностная мера  $\mathbf{P}^m$ , удовлетворяющая условию

$$\mathbf{P}^m(\mathbf{a}_1 \times \dots \times \mathbf{a}_m) = \prod_{i=1}^m \mathbf{P}(\mathbf{a}_i)$$

# Методы, основанные на обучении по прецедентам

В процессе обучения производится поиск эмпирических закономерностей, связывающих прогнозируемую переменную  $Y$  с переменными  $X_1, \dots, X_n$ .

Данные закономерности далее используются при прогнозировании.

Методы, основанные на обучении по прецедентам, также принято называть

Методами машинного обучения (Machine learning)

# Способы поиска закономерностей

Основным способом поиска закономерностей является поиск некотором априори заданном семействе алгоритмов прогнозирования


$\tilde{M} = \{A : \tilde{X} \rightarrow \tilde{Y}\}$  алгоритма, наилучшим образом

аппроксимирующего связь переменных из набора  $X_1, \dots, X_n$  с переменной  $Y$  на обучающей выборке, где  $\tilde{X}$  - область возможных значений векторов переменных  $X_1, \dots, X_n$   
 $\tilde{Y}$  - область возможных значений переменной  $Y$ .

Пусть  $\lambda[y_j, A(\mathbf{x}_j)]$  - величина “потерь”, произошедших в результате использования  $A(\mathbf{x}_j)$  в качестве прогноза значения  $Y$ . Тогда одним из способов обучения является **минимизация функционала эмпирического риска на обучающей выборке**


$$Q(\tilde{S}_t, A) = \frac{1}{m} \sum_{j=1}^m \lambda[y_j, A(\mathbf{x}_j)]$$

# Примеры



Показана закономерность: объекты  
класса K1 и класса K2 из  
обучающей выборке St находятся по  
разные стороны прямой.

# Примеры



Показана закономерность: наличие линейной зависимости между Y и X

# Способы поиска закономерностей

Частные случаи функции потерь.

При прогнозировании непрерывных величин могут использоваться

$$\lambda[y_j, A(\mathbf{x}_j)] = [y_j - A(\mathbf{x}_j)]^2 \text{ - квадрат ошибки,}$$

$$\lambda[y_j, A(\mathbf{x}_j)] = |y_j - A(\mathbf{x}_j)| \text{ - модуль ошибки.}$$

В случае задачи распознавания функция потерь может быть равной 0 при правильной классификации и 1 при ошибочной. При этом функционал эмпирического риска равен числу ошибочных классификаций.

# Обобщающая способность

Точность алгоритма прогнозирования на всевозможных новых не использованных для обучения объектах, которые возникают в результате процесса, соответствующего рассматриваемой задаче прогнозирования принято называть

**Обобщающей способностью** Иными словами

обобщающую способность алгоритма прогнозирования можно определить как точность на всей генеральной совокупности.

Мерой обобщающей способности служит математическое ожидание потерь по генеральной

совокупности -  $E_{\Omega}\{\lambda[Y, A(\mathbf{x})]\}$

# Обобщающая способность

Обобщающая способность может быть записана в виде

$$E_{\Omega}\{\lambda[Y, A(\mathbf{x})]\} = \int_{\mathbf{M}} E\{\lambda[Y, A(\mathbf{x})] \mid \mathbf{x}\} p(\mathbf{x}) dx_1 \dots dx_n,$$

где  $p(\mathbf{x})$  - плотность вероятности в точке  $\mathbf{x}$

Интегрирование ведётся по области  $M$ , принадлежащей пространству  $\mathbf{R}^n$  вещественных векторов размерности  $n$ , из которой принимают значения  $X_1, \dots, X_n$



# Обобщающая способность

При решении задач прогнозирования основной целью является достижение **максимальной обобщающей способности**

# Эффект переобучения


- Расширение модели  $\tilde{M} = \{A : \tilde{X} \rightarrow \tilde{Y}\}$ , увеличение её сложности всегда приводит к повышению точности аппроксимации на обучающей выборке. Однако повышение точности на обучающей выборке, связанное с увеличением сложности модели, часто не ведёт к увеличению обобщающей способности. Более того, обобщающая способность может даже снижаться. Различие между точностью на обучающей выборке и обобщающей способностью при этом возрастает. Данный эффект называется **эффектом переобучения**.

# Эффект переобучения



На левом слайде показано, что использование кусочно-линейной модели (красная линия) позволяет значительно лучше аппроксимировать зависимость на обучающей выборке St, чем простая линейная регрессия (тёмно-синяя прямая). Однако оказывается (правый слайд), что точность аппроксимации новой контрольной выборки Sc, взятой из той же самой генеральной совокупности, для простой линейной регрессии значительно лучше, чем для кусочно-линейной.

# Эффект переобучения



На левом слайде показано, что использование кусочно-линейной границы (красная линия) позволяет значительно лучше разделить объекты класса K1 и класса K2 (●) обучающей выборке St, чем простая линейная граница (тёмно-синяя прямая). Однако оказывается (правый слайд), что точность на новой контрольной выборки Sc, взятой из той же самой генеральной совокупности, для простой линейной границы значительно лучше, чем для кусочно-линейной

# Для какого алгоритма прогнозирования достигается максимальная обобщающая способность?

В случае, если при прогнозе  $Y$  в точке  $\mathbf{x}$  используется Величина  $A(\mathbf{x})$ , а величиной потерь является квадрат ошибки

( т.е.  $\lambda[Y, A(\mathbf{x})] = [Y - A(\mathbf{x})]^2$  ), справедливо разложение:

$$E\{\lambda[Y, A(\mathbf{x})] | \mathbf{x}\} = E\{[Y - A(\mathbf{x})]^2 | \mathbf{x}\} =$$

$$= E\{[Y - E(Y | \mathbf{x}) + E(Y | \mathbf{x}) - A(\mathbf{x})]^2 | \mathbf{x}\} = E\{[Y - E(Y | \mathbf{x})]^2 | \mathbf{x}\} +$$

$$+ E\{[A(\mathbf{x}) - E(Y | \mathbf{x})]^2 | \mathbf{x}\} + 2[A(\mathbf{x}) - E(Y | \mathbf{x})]E\{[Y - E(Y | \mathbf{x})] | \mathbf{x}\}$$

# Для какого алгоритма прогнозирования достигается максимальная обобщающая способность?

Здесь мы воспользовались простейшими свойствами условных математических ожиданий. Для произвольных случайных функций  $\zeta_1$  и  $\zeta_2$

$$E[(\zeta_1 + \zeta_2) | \mathbf{x}] = E[\zeta_1 | \mathbf{x}] + E[\zeta_2 | \mathbf{x}] ;$$

для произвольной константы  $C$  и произвольной  $\zeta$  случайной функции  $E[C\zeta | \mathbf{x}] = CE[\zeta | \mathbf{x}] ;$

$$E(1 | \mathbf{x}) = 1$$

# Для какого алгоритма прогнозирования достигается максимальная обобщающая способность

Однако

$$2[E(Y | \mathbf{x}) - A(\mathbf{x})]E\{[Y - E(Y | \mathbf{x})] | \mathbf{x}\} = 0$$

х

Откуда следует, что

$$E\{[Y - A(\mathbf{x})]^2 | \mathbf{x}\} = [E(Y | \mathbf{x}) - A(\mathbf{x})]^2 + E\{[Y - E(Y | \mathbf{x})]^2 | \mathbf{x}\} \quad (1)$$

Из формулы (1) хорошо видно, что наилучший прогноз должен обеспечивать алгоритм вычисляющий прогноз равный  $A(\mathbf{x}) = E(Y | \mathbf{x})$

# Для какого алгоритма распознавания достигается максимальная обобщающая способность

## Байесовский классификатор

Пусть в точке  $\mathbf{x} \in \mathbf{R}^n$  объекты из классов  $K_1, \dots, K_L$

встречаются с вероятностями  $\mathbf{P}(K_1 | \mathbf{x}), \dots, \mathbf{P}(K_L | \mathbf{x})$

Тогда распознаваемый объект со значением вектора

прогностических переменных  $\mathbf{x}$  должен быть отнесён

в класс  $K_*$  максимальным значением  $\mathbf{P}(K_* | \mathbf{x})$

# Байесовский классификатор

Покажем, что при справедливости предположения о том, что всю доступную информацию о распределении объектов по классам содержат переменные  $X_1, \dots, X_n$ , байесовский классификатор обеспечивает наименьшую ошибку распознавания.

Пусть используется классификатор, относящий в некоторой точке  $\mathbf{x}$  в классы  $K_1, \dots, K_L$  доли объектов  $v_1(\mathbf{x}), \dots, v_L(\mathbf{x})$ , соответственно.

# Байесовский классификатор

Общая вероятность ошибочных классификаций в точке  $\mathbf{x}$

составляет

$$\sum_{i=1}^L [1 - \nu_i(\mathbf{x})] \mathbf{P}(K_i | \mathbf{x}) = 1 - \sum_{i=1}^L \nu_i(\mathbf{x}) \mathbf{P}(K_i | \mathbf{x}) \quad (1)$$

Задача поиска минимума ошибки (2) сводится к задаче линейного

программирования

$$\sum_{i=1}^L \nu_i \mathbf{P}(K_i | \mathbf{x}) \rightarrow \max$$

При ограничениях

$$\sum_{i=1}^L \nu_i = 1 \quad \nu_i \geq 0 \quad \text{при } i = 1, \dots, L$$

# Байесовский классификатор

Решение задачи линейного программирования находится в вершине симплекса задаваемого ограничения и является бинарным вектором размерности  $L$   
 $(0, \dots, 1, \dots, 0)$ . При этом 1 находится в позиции, соответствующей максимальной условной вероятности

$$\mathbf{P}(K_i | \mathbf{x})$$

# Поиск оптимальных алгоритмов прогнозирования и распознавания

Однако для вычисления условных математических ожиданий  $E(Y | \mathbf{x})$

или условных вероятностей  $\mathbf{P}(K_i | \mathbf{x}) \quad i = 1, \dots, L$

необходимы знания конкретного вида вероятностных распределений, присущих решаемой задаче. Такие знания в принципе могут быть получены с использованием известного метода максимального правдоподобия.

# Метод максимального правдоподобия

Метод максимального правдоподобия используется в математической статистике для аппроксимации вероятностных распределений по выборкам данных. В общем случае ММП требует априорных предположений о типе распределений. Значения параметров  $(\theta_1, \dots, \theta_r)$ , задающих конкретный вид распределений, ищутся путём максимизации функционала правдоподобия. Функционал правдоподобия представляет собой произведение плотностей вероятностей на объектах обучающей выборки.

# Метод максимального правдоподобия

Функционал правдоподобия имеет вид

$$L(\tilde{S}_t, \theta_1, \dots, \theta_r) = \prod_{j=1}^m p(y_j, \mathbf{x}_j | \theta_1, \dots, \theta_r)$$

Наряду с методом минимизации эмпирического риска метод ММП является одним из важнейших инструментов настройки алгоритмов распознавания или регрессионных моделей. Следует отметить тесную связь между обоими подходами.

# Поиск оптимальных алгоритмов прогнозирования и распознавания

Для подавляющего числа приложений ни общий вид распределений, ни значения конкретных их параметров неизвестны.

В связи с этим возникло большое число разнообразных подходов к решению задач прогнозирования, использование которых позволяло добиваться определённых успехов при решении конкретных задач.

# МЕТОДЫ ПРОГНОЗИРОВАНИЯ

- Статистические методы
- Линейные модели регрессионного анализа
- Различные методы, основанные на линейной разделимости
- Методы, основанные на ядерных оценках
- Нейросетевые методы
- Комбинаторно-логические методы и алгоритмы вычисления оценок
- Алгебраические методы
- Решающие или регрессионные деревья и леса
- Методы, основанные на опорных векторах

# Эмпирические методы оценки обобщающей способности

Обобщающая способность может оцениваться по случайной выборке объектов из одной и той же генеральной совокупности, соответствующей исследуемому процессу, которую принято называть контрольной выборкой. Контрольная выборка не должна содержать объекты из обучающей выборки.

- Контрольная выборка имеет вид  $\tilde{S}_c = \{(y_1, \mathbf{x}_1), \dots, (y_{m_c}, \mathbf{x}_{m_c})\}$  где  $y_j$  - значение переменной  $Y$  для  $j$ -го объекта;  
 $\mathbf{x}_j$  - значение вектора переменных  $X_1, \dots, X_n$  для  $j$ -го объекта;
- $m_c$  - число объектов в  $\tilde{S}_c$  ;

# Эмпирические методы оценки обобщающей способности

- Обобщающая способность  $A$  может оцениваться с помощью функционала риска

$$Q(\tilde{S}_c, A) = \frac{1}{m} \sum_{j=1}^{m_c} \lambda[y_j, A(\mathbf{x}_j)]$$

При  $m_c \rightarrow \infty$  согласно закону больших чисел  $Q(\tilde{S}_c, A) \rightarrow E_\Omega\{\lambda[Y, A(\mathbf{x})]\}$

# Эмпирические методы оценки обобщающей способности

Обычно при решении задачи прогнозирования по прецедентам в распоряжении исследователей сразу оказывается весь массив существующих эмпирических данных  $\tilde{S}_{in}$ . Для оценки точности прогнозирования могут быть использованы следующие стратегии.

- 1) Выборка  $\tilde{S}_{in}$  случайным образом расщепляется на выборку  $\tilde{S}_t$  для обучения алгоритма прогнозирования и выборку  $\tilde{S}_c$  для оценки точности
- 2) Процедура кросс-проверки. Выборка  $\tilde{S}_{in}$  случайным образом расщепляется на выборки  $\tilde{S}_A$  и  $\tilde{S}_B$ . На первом шаге  $\tilde{S}_A$  используется для обучения и  $\tilde{S}_B$  для контроля. На следующем шаге  $\tilde{S}_A$  и  $\tilde{S}_B$  меняются местами

# Эмпирические методы оценки обобщающей способности

- 3) Процедура скользящего контроля выполняется по полной выборке  $\tilde{S}_{in}$  за  $m = |\tilde{S}_{in}|$  шагов .  
на  $j$ -ом шаге формируется обучающая выборка  $\tilde{S}_t^j = \tilde{S}_{in} \setminus s_j$ ,  
где  $s_j = (y_j, \mathbf{x}_j)$   $j$ -ый объект  $\tilde{S}_{in}$  ,  
и контрольная выборка  $\tilde{S}_c$  , состоящая из единственного  
объекта  $s_j$ .

Процедура скользящего контроля вычисляет оценку обобщающей способности

$$Q_{sc}(\tilde{S}_{in}, A) = \frac{1}{m} \sum_{j=1}^m \lambda[y_j, A(\mathbf{x}_j, \tilde{S}_t^j)]$$

# Несмешённость оценки скользящего контроля

Под несмешённостью оценки скользящего контроля  
понимается выполнение следующего равенства

$$E_{\Omega_m} \{ Q_{sc} [\tilde{S}_m, A] \} = E_{\Omega_{m-1}} E_{\Omega} \{ \lambda [Y, A(\mathbf{x}, \tilde{S}_{m-1})] \}$$

Покажем, что несмешённость имеет место, если выборка  
 $\tilde{S}_{in}$  является независимой выборкой объектов из  
генеральной совокупности  $\Omega$

# Несмешённость оценки скользящего контроля

Напомним, что в этом случае  $\tilde{S}_{in}$  является элементом вероятностного пространства  $(\Omega_m, \Sigma_m, \mathbf{P}_m)$ . Произвольная подвыборка  $\tilde{S}_{in}$  размером  $m' < m$  с произвольным порядком объектов является элементом вероятностного пространства  $(\Omega_{m'}, \Sigma_{m'}, \mathbf{P}_{m'})$ , которое строится также как и вероятностное пространство  $(\Omega_m, \Sigma_m, \mathbf{P}_m)$

# Несмешённость оценки скользящего контроля

$$\begin{aligned} E_{\Omega_m}\{Q_{sc}[\tilde{S}_m, A]\} &= E_{\Omega_m}\left\{\frac{1}{m} \sum_{j=1}^m \lambda[y_j, A(\mathbf{x}_j, \tilde{S}_t^j)]\right\} = \\ &= \frac{1}{m} \sum_{j=1}^m E_{\Omega_m}\{\lambda[y_j, A(\mathbf{x}_j, \tilde{S}_t^j)]\} \end{aligned}$$

Однако из ранее сказанного следует, что  $\forall j$   
выборка  $\tilde{S}_t^j$  является элементом пространства  $\Omega_{m-1}$ .  
Объект  $(y_j, \mathbf{x}_j)$  является элементом  $\Omega$

# Несмешённость оценки скользящего контроля

Из упомянутых свойств, а также из теоремы Фубини следует

$$E_{\Omega_m}\{\lambda[y_j, A(\mathbf{x}_j, \tilde{S}_t^j)]\} = E_{\Omega_{m-1}}E_{\Omega}\{\lambda[Y, A(\mathbf{x}, \tilde{S}_{m-1})]\}$$

Таким образом

$$E_{\Omega_m}\{Q_{sc}[\tilde{S}_m, A]\} = \frac{1}{m} \sum_{i=1}^m E_{\Omega_{m-1}}E_{\Omega}\{\lambda[Y, A(\mathbf{x}, \tilde{S}_{m-1})]\} =$$

$$= E_{\Omega_{m-1}}E_{\Omega}\{\lambda[Y, A(\mathbf{x}, \tilde{S}_{m-1})]\}$$