

Линейные модели

- Описывают линейную связь независимых переменных со средней величиной зависящей переменной
- Определяют если включение дополнительных независимых переменных позволяет учитывать большую часть вариации чем простая средняя
- Позволяют сделать выводы о популяциях (различаются ли средние зависимости между переменными) на основании выборки
- Используются для описания, предсказания или контроля

Однофакторный ANOVA (1 фактор - качественный)

$$Y_{ij} = \beta_0 + \beta_i + \varepsilon_{ij}$$

Двухфакторный ANOVA (2 factors)

$$Y_{ij} = \beta_0 + \beta_{ti} + \beta_{di} + \varepsilon_{ij}$$

Простая регрессионная модель (одна численная переменная)

$$Y_{ij} = \beta_0 + \beta_1 X + \varepsilon_{ij}$$


Модель множественной регрессии (2 или больше численной переменных)

$$Y_{ij} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon_{ij}$$

Анализ ковариации (численные переменные и факторы)

$$Y_{ij} = \beta_0 + \beta_1 t + \beta_2 X + \varepsilon_{ij}$$


Простая линейная регрессия



Create a Fork Length to Total Length Conversion Equation

$$TL = \beta_0 + \beta_1 * FL$$


Простая линейная регрессия



Create a Fork Length to Total Length Conversion Equation


$$TL = \beta_0 + \beta_1 * FL$$

“Y” зависимая переменная




“X” независимая переменная


Наклон и пересечение



Предсказанная величина регрессии



ОТКЛОНЕНИЯ




Предположения относительно ошибок

- Каждая ошибка принадлежит нормальному распределению
- Постоянная дисперсия для всех уровней X
- Ошибки распределены независимо

Эти предпосылки важны для заключений о значительности модели и параметров!

Ошибки имеют нормальное распределение вокруг средней величины




Условия линейных моделей

- Y независимы (выбор одной не влияет на выбор другой величины, обеспечивается случайной выборкой)
(f correlations, generalized estimating equation)
- X зафиксированы и измерены без ошибки
(random effects models; measurement error models)
- Мат ожидание (средняя) Y для любого данного значения X описывается линейной функцией
(if nonlinear, generalized additive models)
- Для каждого X_i , Y s независимы и нормально распределены
(if not normal, generalized linear models)
- Y при данных X имеют постоянную дисперсию (гомосцедастичны)
(if heteroscedastic, generalized linear models)


Обобщенные линейные модели

- Расширение линейных моделей которые позволяют работать с распределениями отличными от нормального и учитывать нелинейность в структуре модели



- Для оценки параметров использует метод максимального правдоподобия

Распределение ошибок может иметь различные формы



Случайная компонента (распределение ошибки)

- Непрерывные и дискретные распределения экспоненциального семейства

Распределение

тип данных

Normal

непрерывное

Gamma

непрерывное

Inverse Gaussian

непрерывное

Binomial


дискретное

Poisson


дискретное

Continuous Distributions


Normal (Gaussian)





Gamma




Inverse Gaussian



Discrete Distributions



Available Discrete Distribution



See Distributions.xls

Обобщенные линейные модели

- Обобщенная линейная модель состоит из трех компонентов :
 - Случайная компонента (ошибки) определяет условное распределение зависимой переменной для данных независимых переменных (предполагает что ошибки суммируются)
 - систематическая, линейная компонента независимых переменных

$$g(\mu) = \eta = \beta_0 + t + \beta_1 X_1 + \beta_2 t * X_1$$

- Связная функция (g) которая линеаризует связь между средней величиной зависимой переменной и независимых переменных

ФУНКЦИИ СВЯЗИ

пример: логистическая регрессия – p зависит от независимых переменных (коварианты)

$$p_i = \frac{e^{\beta_0 + \beta_1 X_i}}{1 + e^{\beta_0 + \beta_1 X_i}}$$

- Можно оценить с помощью нелинейных методов

$$\log\left(\frac{p_i}{1 - p_i}\right) = \beta_0 + \beta X_i \quad \text{Logit link function}$$

ФУНКЦИИ СВЯЗИ

Family

Normal

Gamma

common



Inverse Gaussian

Binomial

Poisson

“Natural” and Alternate Links

identity, log, $1/\mu$

log, **$1/\mu$** , identity

$1/\mu^2$, inverse, identity, log

logit, probit, cloglog, cauchit, log

log, identify, sqrt

Natural links are the technical link associated with the error distribution. Slight information is lost if other links are used.

Link functions add another layer of diagnostics!

Дисперсия в GLMs

- Каждое распределение имеет определенную связь между средней и дисперсией средней при разных X

<u>Распределение</u>	<u>дисперсия</u>
Normal	константа
Gamma	μ^2/v ($v=1/CV^2$)
Inverse Gaussian	μ^3/λ
Binomial	$\mu(1-\mu)$
Poisson	μ
Neg. Binomial	$\mu+\mu^2/k$

Функция дисперсии добавляет новый уровень диагностики!

- Designate Model and Error Relationship

$$\mu = \alpha X^{\beta} + \varepsilon \quad - \text{additive error}$$

$$\mu = \alpha X^{\beta} \varepsilon \quad - \text{multiplicative error}$$

Если ошибки перемножаются, трансформировать все уравнение чтобы линеаризовать модель а ошибки складывающимися

$$\log_{10} W = a + \beta \cdot \log_{10}(L) + \varepsilon$$

- **выбрать функцию связи**

если ошибки складываются, выбрать функцию связи чтобы сделать линейной X (исследовать литературу, использовать натуральную связь)

- **выбрать распределение ошибки**

Select Models and Relationships

Family	Model	Link	Variance
Gaussian	$\mu = \beta_0 + \beta_1 X_1 + \varepsilon$	identity	constant
Gamma	$\mu = e^{\beta_0 + \beta_1 X_1} + \varepsilon$	log	μ^2
	$\mu = \frac{\alpha_0 X_1}{h + X_1} + \varepsilon$	inverse	μ^2
Poisson	$\mu = e^{\beta_0 + \beta_1 X_1} + \varepsilon$	log	μ
	$\mu = te^{\beta_0 + \beta_1 X_1} + \varepsilon$	log	μ
Binomial	$\mu = \frac{e^{\beta_0 + \beta_1 X_1}}{1 + e^{\beta_0 + \beta_1 X_1}} + \varepsilon$	logit	$\mu(1 - \mu)$