


Data Mining & Machine Learning

Dipl.-Inf. Christoph Carl Kling





DM@C-Kling.de

Methode

Eigenschaften

Maximum likelihood estimation (MLE)


$$\max(p(c|p))$$

- Einfach
- Standard
- Bei wenigen Beobachtungen naiv!



Maximum a posteriori estimation (MAP)


$$\max(p(p|c)) = \max(p(c|p) \cdot p(p))$$



- Erlaubt Prior
- Auch bei wenigen Beobachtungen gut

Bayesian Inference

$$E(\hat{p}) = \int_0^1 p \cdot p(c|p) \cdot p(p) dp$$



- Berücksichtigt ganze Verteilung, nicht nur das Maximum

$$\text{Beta}(\alpha, \beta) = \frac{p^{\alpha-1} \cdot (1-p)^{\beta-1}}{Z}$$

$$Z = \int_0^1 p^{\alpha-1} \cdot (1-p)^{\beta-1} dp = \frac{\Gamma(\alpha) \cdot \Gamma(\beta)}{\Gamma(\alpha + \beta)}$$

$Beta(\alpha, \beta)$

$$E(\hat{p}) = \int_0^1 p \cdot p^{\alpha-1} \cdot (1-p)^{\beta-1} dp = \frac{\alpha}{\alpha + \beta}$$

$$posterior = \frac{likelihood \cdot prior}{evidence}$$

For binomial distributed observations:

$$\begin{aligned} p(p|\mathbf{c}) &\propto p(\mathbf{c}|p) \cdot p(p) \\ &= p^{n_1} \cdot (1-p)^{n_0} \cdot p^{\alpha-1} \cdot (1-p)^{\beta-1} \\ &= p^{n_1+\alpha-1} \cdot (1-p)^{n_0+\beta-1} \\ &= Beta(n_1 + \alpha, n_0 + \beta) \end{aligned}$$

$$\text{Beta}(n_1 + \alpha, n_0 + \beta)$$

$$\Rightarrow E(\hat{p}) = \frac{n_1 + \alpha}{n_1 + \alpha + n_0 + \beta}$$

Das ist die Parameter-Schätzung für p mit **Bayesian inference!**

Maximum likelihood estimation

$$\max_p p(p(\mathbf{c}|p)) = \frac{n_1}{n_1 + n_0}$$

n_1 : Anzahl Würfe Kopf
 n_0 : Anzahl Würfe Zahl


Maximum a posteriori estimation

$$\max_p p(p(p|\mathbf{c})) = \frac{n_1 + \alpha - 1}{n_1 + \alpha - 1 + n_0 + \beta - 1}$$

Bayesian inference

$$E(\hat{p}) = \frac{n_1 + \alpha}{n_1 + \alpha + n_0 + \beta}$$

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots$$




$$\hat{y} = \beta_0 + \beta_1 x_1$$

Annahmen:

- Linearer Zusammenhang zwischen x und y
- Varianz konstant
- Keine starke Korrelation zwischen zwei Variablen

y = Größe	x1 = Geschlecht	x2 = Gewicht
168	1	65
172	0	80
164	1	52
187	0	120
194	0	90

$$\pi(x) = \frac{e^{(\beta_0 + \beta_1 x)}}{e^{(\beta_0 + \beta_1 x)} + 1} = \frac{1}{e^{-(\beta_0 + \beta_1 x)} + 1}$$



$$\pi(x) = \frac{e^{(\beta_0 + \beta_1 x)}}{e^{(\beta_0 + \beta_1 x)} + 1} = \frac{1}{e^{-(\beta_0 + \beta_1 x)} + 1}$$

$$\ln\left(\frac{\pi(x)}{1 - \pi(x)}\right) = \beta_0 + \beta_1 x$$



Münze mit Gewicht x_1 auf Rückseite

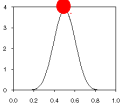
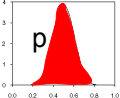
Kopf	6	4	3	3	2
Zahl	4	6	7	7	8
x_1	0g	1g	2g	3g	4g

Data Mining & Machine Learning

Dipl.-Inf. Christoph Carl Kling



Parameter Estimation

Methode	Eigenschaften
Maximum likelihood estimation (MLE) $\max(p(c p))$	- Einfach - Standard - Bei wenigen Beobachtungen naiv! 😊
Maximum a posteriori estimation (MAP) $\max(p(p c)) = \max(p(c p) \cdot p(p))$ 	- Erlaubt Prior - Auch bei wenigen Beobachtungen gut
Bayesian Inference $E(\hat{p}) = \int_0^1 p \cdot p(c p) \cdot p(p) dp$ 	- Berücksichtigt ganze Verteilung, nicht nur das Maximum

Beta distribution

$$\text{Beta}(\alpha, \beta) = \frac{p^{\alpha-1} \cdot (1-p)^{\beta-1}}{Z}$$

$$Z = \int_0^1 p^{\alpha-1} \cdot (1-p)^{\beta-1} dp = \frac{\Gamma(\alpha) \cdot \Gamma(\beta)}{\Gamma(\alpha + \beta)}$$

Expected value for p

$Beta(\alpha, \beta)$

$$E(\hat{p}) = \int_0^1 p \cdot p^{\alpha-1} \cdot (1-p)^{\beta-1} dp = \frac{\alpha}{\alpha + \beta}$$

Posterior probability

$$\text{posterior} = \frac{\text{likelihood} \cdot \text{prior}}{\text{evidence}}$$

For binomial distributed observations:

$$\begin{aligned} p(p|\mathbf{c}) &\propto p(\mathbf{c}|p) \cdot p(p) \\ &= p^{n_1} \cdot (1-p)^{n_0} \cdot p^{\alpha-1} \cdot (1-p)^{\beta-1} \\ &= p^{n_1+\alpha-1} \cdot (1-p)^{n_0+\beta-1} \\ &= \text{Beta}(n_1 + \alpha, n_0 + \beta) \end{aligned}$$

Expected value for p

$$\text{Beta}(n_1 + \alpha, n_0 + \beta)$$

$$\Rightarrow E(\hat{p}) = \frac{n_1 + \alpha}{n_1 + \alpha + n_0 + \beta}$$

Das ist die Parameter-Schätzung für p mit **Bayesian inference!**

Estimation of p

Maximum likelihood estimation

$$\max_p p(\mathbf{c}|p) = \frac{n_1}{n_1 + n_0}$$

n1: Anzahl Würfe Kopf
n0: Anzahl Würfe Zahl

Maximum a posteriori estimation

$$\max_p p(p|\mathbf{c}) = \frac{n_1 + \alpha - 1}{n_1 + \alpha - 1 + n_0 + \beta - 1}$$


Bayesian inference

$$E(\hat{p}) = \frac{n_1 + \alpha}{n_1 + \alpha + n_0 + \beta}$$

Lineare Regression

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots$$

Lineare Regression



$$\hat{y} = \beta_0 + \beta_1 x_1$$

Lineare Regression

Annahmen:


- Linearer Zusammenhang zwischen x und y
- Varianz konstant
- Keine starke Korrelation zwischen zwei Variablen

Lineare Regression

y = Größe	x1 = Geschlecht	x2 = Gewicht
168	1	65
172	0	80
164	1	52
187	0	120
194	0	90

Logistische Regression

$$\pi(x) = \frac{e^{(\beta_0 + \beta_1 x)}}{e^{(\beta_0 + \beta_1 x)} + 1} = \frac{1}{e^{-(\beta_0 + \beta_1 x)} + 1}$$



Logistische Regression

$$\pi(x) = \frac{e^{(\beta_0 + \beta_1 x)}}{e^{(\beta_0 + \beta_1 x)} + 1} = \frac{1}{e^{-(\beta_0 + \beta_1 x)} + 1}$$

$$\ln\left(\frac{\pi(x)}{1 - \pi(x)}\right) = \beta_0 + \beta_1 x$$

Logistische Regression



Münze mit Gewicht x_1 auf Rückseite

Kopf	6	4	3	3	2
Zahl	4	6	7	7	8
<hr/>					
x_1	0g	1g	2g	3g	4g