

パターン認識と機械学習

1.2.4 ガウス分布

小野寺喜行

ガウス分布

- 単一の実数値変数 x に対し

$$N(x | \mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left\{-\frac{1}{2\sigma^2}(x - \mu)^2\right\}$$

と定義

- 以下の2つのパラメータを持つ


平均 (mean) : μ

分散 (variance) : σ^2

分散

- 分散の平方根 σ :
標準偏差 (standard deviation)
- 分散の逆数 $\beta = 1 / \sigma^2$:
精度パラメータ (precision parameter)

ガウス分布 曲線



確率密度の用件

- 定義より

$$N(x | \mu, \sigma^2) > 0$$

- また、

$$\int_{-\infty}^{\infty} N(x | \mu, \sigma^2) dx = 1$$

- 確率密度の満たすべき2つの用件を満たす

平均

- x の平均値

$$E[x] = \int_{-\infty}^{\infty} N(x | \mu, \sigma^2) x dx = \mu$$

分散

- 2次のモーメント

$$E[x^2] = \int_{-\infty}^{\infty} N(x | \mu, \sigma^2) x^2 dx = \mu^2 + \sigma^2$$

- x の分散

$$\text{var}[x] = E[x^2] - E[x]^2 = \sigma^2$$

モード(最頻値)

- 分布の最大値を与える x はモード(最頻値)である。
- ガウス分布では、モードは平均に一致する。

D次元ベクトル

- D次元ベクトルの連続変数 \mathbf{x} に対してのガウス分布

$$N(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\boldsymbol{\Sigma}|^{1/2}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\}$$

D次元ベクトル $\boldsymbol{\mu}$: 平均

D×D行列 $\boldsymbol{\Sigma}$: 共分散

$|\boldsymbol{\Sigma}|$: $\boldsymbol{\Sigma}$ の行列式

独立同分布

- データ点が同じ分布から独立に生成されるとき、独立同分布 (independent identically distributed) (i.d.d.) であるという。
- 2つの独立な事象の同時確率は、それぞれの事象の周辺確率の積で与えられる。

データ集合 \mathbf{x}

- スカラー変数 x の N 個の観測値からなるデータ集合 $\mathbf{x} = (x_1, \dots, x_N)^T$
- データ集合 \mathbf{x} は i.i.d. であるので、 μ と σ^2 が与えられたとき、データ集合の確率は

$$p(\mathbf{x} | \mu, \sigma^2) = \prod_{n=1}^N N(x_n | \mu, \sigma^2)$$

- μ と σ^2 の関数とみなすと、ガウス分布に対する尤度関数である

データ集合からパラメータを決める

- 観測されたデータ集合を使って確率分布のパラメータを決める方法



尤度関数を最大にするようなパラメータの値を求める

- 実際には尤度関数の対数を最大化する方が便利

尤度関数の対数を最大化

- 対数は単調増加関数であるので、関数そのものの最大化と等価
- その後の数学的な解析を単純化
- 小さな確率値の積を計算する際の、計算機の数値精度のアンダーフローを解決できる

対数尤度関数

- $N(x | \mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{1/2}} \exp\left\{-\frac{1}{2\sigma^2}(x - \mu)^2\right\}$

$$p(\mathbf{x} | \mu, \sigma^2) = \prod_{n=1}^N N(x_n | \mu, \sigma^2)$$

より

$$\ln p(\mathbf{x} | \mu, \sigma^2) = -\frac{1}{2\sigma^2} \sum_{n=1}^N (x_n - \mu)^2 - \frac{N}{2} \ln \sigma^2 - \frac{N}{2} \ln(2\pi)$$

最尤推定の解

- μ に関して対数尤度関数を最大化すると、最尤推定の解が得られ、

$$\mu_{ML} = \frac{1}{N} \sum_{n=1}^N x_n$$

で与えられる

- サンプル平均 (標本平均; sample mean)、すなわち観測値 $\{x_n\}$ の平均

分散に対する最尤解

- σ^2 に関して対数尤度関数を最大化すると、分散に対する最尤解

$$\sigma_{ML}^2 = \frac{1}{N} \sum_{n=1}^N (x_n - \mu_{ML})^2$$

を得る

- サンプル平均 μ_{ML} に関するサンプル分散 (標本分散; sample variance) である

同時最大化

- μ と σ^2 に関して対数尤度関数を同時最大化を行なうとき、ガウス分布の場合は μ と σ^2 は分離して解く事が出来る。

最初に μ_{ML} を評価



その結果を使って
 σ_{ML}^2 を評価

最尤アプローチの重大な限界

- 1変数ガウス分布の最尤パラメータの設定に関する問題
 - ➡ 最尤のアプローチでは特に分布の分散が系統的に過小評価されている
- バイアス (bias) とよばれる現象の一例
- 多項式曲線のフィッティングにおける過学習の問題に関連

分散の過小評価

- 最尤解 μ_{ML}, σ_{ML}^2 はデータ集合の値 x_1, \dots, x_N の関数であることに注意
- パラメータ μ, σ^2 をもつガウス分布に従うデータ集合に関する期待値

$$E[\mu_{ML}] = \mu$$

$$E[\sigma_{ML}^2] = \left(\frac{N-1}{N}\right)\sigma^2$$

分散が $(n-1)/N$ 倍過小評価されることが示される

分散パラメータの不偏推定量

- $E[\sigma_{ML}^2] = \left(\frac{N-1}{N}\right)\sigma^2$ より

$$\tilde{\sigma}^2 = \frac{N}{N-1}\sigma_{ML}^2 = \frac{1}{N-1}\sum_{n=1}^N (x_n - \mu_{ML})^2$$

は分散パラメータの不偏推定量になる

最尤解のバイアス

- 最尤解のバイアスはデータ点の数 N が増えればあまり重大ではなくなる
- $N \rightarrow \infty$ の極限では分散の最尤解は真の分散に一致する

最尤解のバイアス

- N が小さいという理由以外では、深刻な問題にはならない
- しかし、多くのパラメータを持つ複雑なモデルでは、最尤推定に伴う問題ははるかに厳しいものとなる
- 過学習の問題の根本にある