

1. Exclusive OR のパターンを学習することができる TLU ネットワークを図示し, その構造の必然性を説明しなさい。


2. 下記の表のようなテスト-目標属性間の関係があるとき, エントロピーゲインに基づいて決定木を求めなさい。

T1	T2	T3	T4	目標属性
1	0	1	1	1
1	1	1	1	1
1	1	1	0	0
1	0	1	0	0
1	1	0	1	0
1	0	0	1	0
1	1	0	1	0
0	1	0	1	1
0	0	1	1	1
0	1	0	1	1
0	0	0	1	1
0	0	1	0	0
0	1	0	0	0
0	0	1	0	0

3. d 次元ベクトル \mathbf{f}_i ($i=1, \dots, M$) が与えられている. その固有ベクトルを求める方法について考える. $F = [\mathbf{f}_1 \ \dots \ \mathbf{f}_M]$ とすると, 共分散行列を M 倍した行列は $\sum_{i=1}^M \mathbf{f}_i \mathbf{f}_i^T = FF^T$ と表せる. この行列の固有ベクトルを FF^T ではなく $F^T F$ の固有ベクトルから求める方法と, その利点について述べなさい.

4. $f(x)$ の Fourier 変換を $F(\omega) = \int_{-\infty}^{\infty} f(x)e^{-j\omega x} dx$ とする. このとき, $f(x)$ が平行移動したパターン $g(x) = f(x - \mu)$ の Fourier 変換を $F(\omega)$ を用いた式で表しなさい. また, μ に対して不変な特徴を抽出する方法の一つとして, 自己相関関数 $R(\tau) = \int_{-\infty}^{\infty} f(x - \mu + \tau)f(x - \mu)dx$ が考えられる. $R(\tau)$ の Fourier 変換が $\|F(\omega)\|^2$ となることを示しなさい. また, この不変特徴の問題点について説明しなさい.
5. パターン \mathbf{x} を正規直交基底 $\mathbf{u}_i (i = 1, \dots, n)$ が張る部分空間に正射影する行列 P を $U = (\mathbf{u}_1 \ \dots \ \mathbf{u}_n)$ という行列を用いて表現しなさい.
6. 5において、 C 個の部分空間が存在する場合, 各部分空間への射影行列 $P_i (i = 1, \dots, C)$ を用いて, 「 $\mathbf{x}^T P_i \mathbf{x}$ を最大化する i を求める問題」と, 「 $\|\mathbf{x} - P_i \mathbf{x}\|$ を最小化する i を求める問題」は本質的に同じであることを示しなさい.
7. SVM の学習時に必要となる計算量・メモリ量がデータ数およびデータの次元数とどのような関係にあるかについて述べなさい.
8. 共分散行列 Σ の固有値と固有ベクトルがそれぞれ λ_i と $\boldsymbol{\varphi}_i (i = 1 \dots n)$ であるとき, 共分散行列 Σ を λ_i と $\boldsymbol{\varphi}_i$ を用いて表しなさい.


1. Exclusive OR のパターンを学習することができる TLU ネットワークを図示し、その構造の必然性を説明しなさい。



TLU は線形識別面の学習を行う機構である。線形識別面で Exclusive OR のパターンを表現しようとするとき、少なくとも 2 つの TLU が必要になる。どちらのケースでも、線形識別面によって区切られるどちらの半空間にパターンが属するのかが判定する TLU と、それらを総合して、出力として 1 を出すか否かを決定する TLU が存在する必要があるため、上図の構造のネットワークになる。但し、各 TLU の -1 に固定された入力省略している。

2. 下記の表のようなテスト-目標属性間の関係があるとき、エントロピーゲインに基づいて決定木を求めなさい。

T1	T2	T3	T4	目標属性
1	0	1	1	1
1	1	1	1	1
1	1	1	0	0
1	0	1	0	0
1	1	0	1	0
1	0	0	1	0
1	1	0	1	0
0	1	0	1	1
0	0	1	1	1
0	1	0	1	1
0	0	0	1	1
0	0	1	0	0
0	1	0	0	0
0	0	1	0	0



3. d 次元ベクトル f_i ($i=1, \dots, M$) が与えられている。その固有ベクトルを求める方法について考える。

$F = [f_1 \ \dots \ f_M]$ とすると、共分散行列を M 倍した行列は $\sum_{i=1}^M f_i f_i^T = FF^T$ と表せる。この行列の固有ベクトルを FF^T ではなく $F^T F$ の固有ベクトルから求める方法と、その利点について述べなさい。

$F^T F$ の固有ベクトルを ϕ 、固有値を λ とすると、 $F^T F \phi = \lambda \phi$ が成立する。この式の左から F をかけると、 $FF^T F \phi = \lambda F \phi$ が得られる。 $FF^T (F \phi) = \lambda (F \phi)$ と見なすと、 FF^T の固有ベクトルは、 $F \phi$ と表せる。この方法のメリットは、 $d \gg M$ の場合、 FF^T が $d \times d$ であるのに対し $F^T F$ は $M \times M$ と小さくなることである。

4. $f(x)$ の Fourier 変換を $F(\omega) = \int_{-\infty}^{\infty} f(x)e^{-j\omega x} dx$ とする. このとき, $f(x)$ が平行移動したパターン $g(x) = f(x - \mu)$ の Fourier 変換を $F(\omega)$ を用いた式で表しなさい. また, μ に対して不変な特徴を抽出する方法の一つとして, 自己相関関数 $R(\tau) = \int_{-\infty}^{\infty} f(x - \mu + \tau)f(x - \mu)dx$ が考えられる. $R(\tau)$ の Fourier 変換が $\|F(\omega)\|^2$ となることを示しなさい. また, この不変特徴の問題点について説明しなさい.

$$G(\omega) = \int_{-\infty}^{\infty} f(x - \mu)e^{-j\omega x} dx = \int_{-\infty}^{\infty} f(X)e^{-j\omega(X + \mu)} dX = e^{-j\omega\mu} \int_{-\infty}^{\infty} f(X)e^{-j\omega X} dX = e^{-j\omega\mu} F(\omega)$$

$$\int_{-\infty}^{\infty} R(\tau)e^{-j\omega\tau} d\tau = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x - \mu + \tau)f(x - \mu)dx e^{-j\omega\tau} d\tau = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(X + \tau)f(X)dX e^{-j\omega\tau} d\tau$$

変数変換を行い, 次の結果を得る.

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(T)f(X)dXe^{-j\omega(T-X)} dT = \int_{-\infty}^{\infty} f(T)e^{-j\omega T} dT \int_{-\infty}^{\infty} f(X)e^{j\omega X} dX = F(\omega)F^*(\omega) = \|F(\omega)\|^2$$

このようにして得られた不変特徴は, 各周波数成分間の位相情報まで消されているため, 識別に利用できる特徴が少なくなってしまうという問題点がある.

5. パターン \mathbf{x} を正規直交基底 $\mathbf{u}_i (i = 1, \dots, n)$ が張る部分空間に正射影する行列 P を $U = (\mathbf{u}_1 \ \dots \ \mathbf{u}_n)$ という行列を用いて表現しなさい.

$$P = UU^T$$

6. 5において, C 個の部分空間が存在する場合, 各部分空間への射影行列 $P_i (i = 1, \dots, C)$ を用いて, 「 $\mathbf{x}^T P_i \mathbf{x}$ を最大化する i を求める問題」と, 「 $\|\mathbf{x} - P_i \mathbf{x}\|$ を最小化する i を求める問題」は本質的に同じであることを示しなさい.

$\|\mathbf{x} - P_i \mathbf{x}\|$ を最小化することは, $\|\mathbf{x} - P_i \mathbf{x}\|^2$ を最小化することと同値である. これを計算すると, $\|\mathbf{x} - P_i \mathbf{x}\|^2 = (\mathbf{x} - P_i \mathbf{x})^T (\mathbf{x} - P_i \mathbf{x}) = \|\mathbf{x}\|^2 - 2\mathbf{x}^T P_i \mathbf{x} + \mathbf{x}^T P_i^T P_i \mathbf{x}$ となる. $P_i = U_i U_i^T$ から $P_i^T P_i = P_i$ となるので, 結局 $\|\mathbf{x} - P_i \mathbf{x}\|^2 = \|\mathbf{x}\|^2 - \mathbf{x}^T P_i \mathbf{x}$ となる. このうち, \mathbf{x} は i に依存せず最小化とは無関係であるので, $\|\mathbf{x}\|^2$ を無視することができ, $-\mathbf{x}^T P_i \mathbf{x}$ を最小化すればよいことが分かる. これは, $\mathbf{x}^T P_i \mathbf{x}$ を最大化する問題となっている.

7. SVM の学習時に必要となる計算量・メモリ量がデータ数およびデータの次元数とどのような関係にあるかについて述べなさい.

SVM では各データ間の内積によって定義されるマトリクスを用いた 2 次形式を含む目的関数の最適化を行う. このため, データ数 n に対してマトリクスのサイズは n^2 となる. また, この最適化問題を解くための計算量は $O(n^2)$ となる. データの次元数 d は実質的にカーネル関数を計算する際にしか問題にならず, この計算量は $O(dn^2)$ となる. したがって, 次元数が大きい場合でもデータ数が多くなければ, 学習を行うことができる.

8. 共分散行列 Σ の固有値と固有ベクトルがそれぞれ λ_i と $\boldsymbol{\varphi}_i (i = 1 \dots n)$ であるとき, 共分散行列 Σ を λ_i と $\boldsymbol{\varphi}_i$ を用いて表しなさい.

$$\Sigma = V \Lambda V^T = \begin{bmatrix} \boldsymbol{\varphi}_1 & \dots & \boldsymbol{\varphi}_n \end{bmatrix} \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & \lambda_n \end{bmatrix} \begin{bmatrix} \boldsymbol{\varphi}_1^T \\ \vdots \\ \boldsymbol{\varphi}_n^T \end{bmatrix} = \sum_{i=1}^n \lambda_i \boldsymbol{\varphi}_i \boldsymbol{\varphi}_i^T$$