



**KOÇ
ÜNİVERSİTESİ**

Çekirdeklerle öğrenme

Doç. Dr. Mehmet Gönen
mehmetgonen@ku.edu.tr

Endüstri Mühendisliği Bölümü, Mühendislik Fakültesi
Hesaplamalı Biyoloji Bölümü, Tıp Fakültesi

24 Haziran 2019



Çekirdek nedir?

- Çekirdek iki nesne arasındaki benzerlik miktarını hesaplayan bir fonksiyondur.
 - protein ikilileri
 - resim ikilileri
 - döküman ikilileri

- $x_i \in \mathcal{X}$ ve $x_j \in \mathcal{X}$
 - \mathcal{X} = bütün olası proteinler
 - \mathcal{X} = bütün olası resimler
 - \mathcal{X} = bütün olası dökümanlar

- $k: \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$



Çekirdek nedir?

- Veri noktalarımızı genelde $N \times D$ büyüklüğünde bir matris olarak saklarız.




$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1D} \\ x_{21} & x_{22} & \dots & x_{2D} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{ND} \end{bmatrix}$$

- Vektör şeklinde gösterebildiğimiz girdiler için sıklıkla kullanılan çekirdekler:
 - $k_D(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^\top \mathbf{x}_j$
 - $k_P(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^\top \mathbf{x}_j + 1)^q$
 - $k_G(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|_2^2 / s^2) = \exp(-d_{ij}^2 / s^2)$



Çekirdeklere neden ihtiyaç duyuyoruz?

- Doğrusal olmayan öznitelikler çıkarmakta kullanabiliriz.





Çekirdekler neden ihtiyaç duyuyoruz?

- Her geçerli çekirdek fonksiyonu yeni bir öznitelik uzayına karşılık gelmektedir.

$$\Phi: \mathbb{R}^D \rightarrow \mathbb{R}^S \text{ (genelde } S \gg D)$$

- Örneğin $D = 1$ ve $S = 3$

$$\Phi(x_i) = [x_i^2 \quad \sqrt{2}x_i \quad 1]^\top$$

$$\Phi(x_i)^\top \Phi(x_j) = [x_i^2 \quad \sqrt{2}x_i \quad 1] [x_j^2 \quad \sqrt{2}x_j \quad 1]^\top = x_i^2 x_j^2 + 2x_i x_j + 1$$

$$k_P(x_i, x_j) = (x_i x_j + 1)^2 = x_i^2 x_j^2 + 2x_i x_j + 1$$

- 100 piksel \times 100 piksel resimlerde ($D = 10^4$) aynısını yapabilir miyiz?
- Doğrusal olmayan öznitelikleri bu şekilde çıkarmak hesaplama maliyeti açısından uygulanabilir değil.



Çekirdeklere neden ihtiyaç duyuyoruz?

- $N \times D$ matris yerine $N \times N$ matris kullanarak hesaplama ve saklama maliyetini düşürebiliriz.

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1D} \\ x_{21} & x_{22} & \dots & x_{2D} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{ND} \end{bmatrix}$$

$$\mathbf{K} = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & k(\mathbf{x}_1, \mathbf{x}_2) & \dots & k(\mathbf{x}_1, \mathbf{x}_N) \\ k(\mathbf{x}_2, \mathbf{x}_1) & k(\mathbf{x}_2, \mathbf{x}_2) & \dots & k(\mathbf{x}_2, \mathbf{x}_N) \\ \vdots & \vdots & \ddots & \vdots \\ k(\mathbf{x}_N, \mathbf{x}_1) & k(\mathbf{x}_N, \mathbf{x}_2) & \dots & k(\mathbf{x}_N, \mathbf{x}_N) \end{bmatrix}$$



Çekirdeklerle neden ihtiyaç duyuyoruz?

- Belli bir yapıya sahip nesnelere arasındaki benzerlik hesaplamakta kullanabiliriz.
- Örnek: İki protein arasındaki benzerlik

MVLSEGEWQLVLHVWAKVEADVAGHGQDILIRLFKSHPETLEK
FDRVKHLKTEAEMKASEDLKKHGVTVLTALGAILKKKGHHEAE
LKPLAQSHATKHKIPIKYLEFISEAIIHVLHSRHPGNFGADAQ
GAMNKALELFRKDIAAKYKELGYQG

MNIFEMLRIDEGLRLKIYKDTEGYTIGIGHLLTKSPSLNAAA
KSELDKAIGRNTNGVITKDEAEKLFNQDVDAAVRGILRNAKLN
PVYDSLDAVRRALINMVFQMGETGVAGFTNSLRMLQQKRWDE
AAVNLAKSRWYNQTPNRAKRVITTFRTGTWDAYKNL



Çekirdeklerle neden ihtiyaç duyuyoruz?

- Belli bir yapıya sahip nesneler arasındaki benzerlik hesaplamakta kullanabiliriz.
- Örnek: İki resim arasındaki benzerlik





Çekirdeklere neden ihtiyaç duyuyoruz?

- Belli bir yapıya sahip nesnelere arasındaki benzerlik hesaplamakta kullanabiliriz.
- Örnek: İki metin arasındaki benzerlik

(Reuters) - Developed countries face a sharp year-end slowdown led by a contraction in Germany, the OECD said on Thursday, urging central banks to keep rates low or pursue other forms of monetary easing if the downturn becomes entrenched.

(Reuters) - More than 100 spacecraft have been to the moon, including six with U.S. astronauts, but one key piece of information about Earth's natural satellite is still missing - what's inside.



Daha iyi çekirdekler tasarlayabilir miyiz?

- Evet, yapabiliriz.
 - çekirdek fonksiyonlarının parametrelerini seçerek (polinom çekirdeğinin derecesi, Gaussian çekirdeğinin yarıçapı)
 - yeni çekirdek fonksiyonları önererek
 - alan bilgisini çekirdeğin içerisinde kullanarak
 - basit çekirdekleri birleştirerek (çoklu çekirdek öğrenimi)
 - çekirdek fonksiyonunu veriden öğrenerek



Destek vektör makineleri

- Eğitim kümesi: $\{(\mathbf{x}_i, y_i) \in \mathcal{X} \times \{\pm 1\}\}_{i=1}^N$

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1D} \\ x_{21} & x_{22} & \dots & x_{2D} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{ND} \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}$$

- Yeni verilen bir veri noktası $\mathbf{x}_* \in \mathcal{X}$ için sınıf etiketini kestirmek

$$\mathbf{x}_* = [x_{*1} \quad x_{*2} \quad \dots \quad x_{*D}] \quad y_* = [?]$$



Destek vektör makineleri

- \mathcal{X} uzayında bir düzlem

$$\{\mathbf{x} \in \mathcal{X} \mid \langle \mathbf{w}, \mathbf{x} \rangle + b = 0\}$$

- Karar fonksiyonu: $f: \mathcal{X} \rightarrow \{\pm 1\}$


$$\mathbf{x} \mapsto f(\mathbf{x}) = \text{sgn}(\langle \mathbf{w}, \mathbf{x} \rangle + b) \quad \mathbf{w} \in \mathcal{X} \text{ ve } b \in \mathbb{R}$$

- Kanonik düzlem (\mathbf{w}, b)

$$\min_{i=1, \dots, N} |\langle \mathbf{w}, \mathbf{x}_i \rangle + b| = 1$$



Destek vektör makineleri





Destek vektör makineleri

- $\|\mathbf{w}\|_2$ 'yi en küçüklersek iki sınıf arasındaki mesafeyi artırabiliriz.
- Karar fonksiyonu ve kanonik düzlem kullanılarak

$$y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 \quad \forall i$$

- Birincil en iyileme problemi

$$\text{en küçükle } \frac{1}{2} \|\mathbf{w}\|_2^2$$

$$\text{karar değişkenleri } \mathbf{w} \in \mathcal{X}, \quad b \in \mathbb{R}$$

$$\text{kısıtlar } y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 \quad \forall i$$



Destek vektör makineleri

- Basit bir örnek

en küçükle $w^2 - 6w + 5$

karar değişkenleri $w \in \mathbb{R}$

kısıtlar $w - 4 \geq 0$

- Lagrange eşiz fonksiyonu

$$L(w, \alpha) = w^2 - 6w + 5 - \alpha(w - 4)$$

- Birincil değişkene göre türev

$$\frac{\partial L(w, \alpha)}{\partial w} = 0 \Rightarrow w = \frac{\alpha + 6}{2}$$



Destek vektör makineleri

- Eşiz en iyileme problemi (w değerini Lagrange eşiz fonksiyonunun içine yazarak)

$$\text{en büyükle } \frac{-\alpha^2 + 4\alpha - 16}{4}$$

$$\text{karar değişkenleri } \alpha \in \mathbb{R}_+$$

- En iyi çözüm

$$\alpha^* = 2$$

$$w^* = \frac{\alpha^* + 6}{2} = 4$$



Destek vektör makineleri

- Lagrange eşiz fonksiyonu

$$L(\mathbf{w}, b, \boldsymbol{\alpha}) = \frac{1}{2} \|\mathbf{w}\|_2^2 - \sum_{i=1}^N \alpha_i (y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1)$$

- Birincil değişkenlere göre türev

$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\alpha})}{\partial \mathbf{w}} = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i$$

$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\alpha})}{\partial b} = 0 \Rightarrow \sum_{i=1}^N \alpha_i y_i = 0$$



Destek vektör makineleri

■ Eşiz en iyileme problemi

$$\text{en büyükle } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle$$

$$\text{karar değişkenleri } \boldsymbol{\alpha} \in \mathbb{R}_+^N$$


$$\text{kısıtlar } \sum_{i=1}^N \alpha_i y_i = 0$$

■ Karar fonksiyonu

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^N \alpha_i y_i \langle \mathbf{x}_i, \mathbf{x} \rangle + b \right)$$




Destek vektör makineleri





Destek vektör makineleri





Destek vektör makineleri

- Sınıflandırma hatasına izin verdiğimiz durumda kısıtımız şu hale gelmektedir.

$$y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 - \xi_i \quad \forall i$$

- Birincil en iyileme problemi

$$\text{en küçükle } \frac{1}{2} \|\mathbf{w}\|_2^2 + C \sum_{i=1}^N \xi_i$$

$$\text{karar değişkenleri } \mathbf{w} \in \mathcal{X}, \quad b \in \mathbb{R}, \quad \boldsymbol{\xi} \in \mathbb{R}_+^N$$

$$\text{kısıtlar } y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 - \xi_i \quad \forall i$$



Destek vektör makineleri

- Lagrange eşiz fonksiyonu

$$L(\mathbf{w}, b, \boldsymbol{\xi}, \boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{1}{2} \|\mathbf{w}\|_2^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \beta_i \xi_i - \sum_{i=1}^N \alpha_i (y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1 + \xi_i)$$

- Birincil değişkenlere göre ek bir türev

$$\frac{\partial L(\mathbf{w}, b, \boldsymbol{\xi}, \boldsymbol{\alpha}, \boldsymbol{\beta})}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \beta_i \Rightarrow C \geq \alpha_i \geq 0 \quad \forall i$$



Destek vektör makineleri

- Eşiz en iyileme problemi

en büyükle
$$\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \langle \mathbf{x}_i, \mathbf{x}_j \rangle$$


karar değişkenleri $\alpha \in \mathbb{R}_+^N$

kısıtlar
$$\sum_{i=1}^N \alpha_i y_i = 0$$

$C \geq \alpha_i \geq 0 \quad \forall i$



Destek vektör makineleri





Destek vektör makineleri

- $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ terimini $k(\mathbf{x}_i, \mathbf{x}_j)$ ile değiştiriyoruz.

$$\text{en büyük} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j)$$

$$\text{karar değişkenleri } \alpha \in \mathbb{R}_+^N$$

$$\text{kısıtlar } \sum_{i=1}^N \alpha_i y_i = 0$$

$$C \geq \alpha_i \geq 0 \quad \forall i$$

- Karar fonksiyonu

$$f(\mathbf{x}) = \text{sgn} \left(\sum_{i=1}^N \alpha_i y_i k(\mathbf{x}_i, \mathbf{x}) + b \right)$$



Gauss süreci

- Eğitim kümesi: $\{(\mathbf{x}_i, y_i) \in \mathcal{X} \times \mathbb{R}\}_{i=1}^N$

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1D} \\ x_{21} & x_{22} & \dots & x_{2D} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{ND} \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}$$

- Yeni verilen bir veri noktası $\mathbf{x}_* \in \mathcal{X}$ için hedef çıktığı kestirmek

$$\mathbf{x}_* = [x_{*1} \quad x_{*2} \quad \dots \quad x_{*D}] \quad y_* = [?]$$



Gauss süreci

- Normal dağılım: $\mathcal{N}(x; \mu, \sigma^2)$

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

- Çok değişkenli normal dağılım: $\mathcal{N}(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma})$

$$p(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^D |\boldsymbol{\Sigma}|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$



Gauss süreci

$$y_i = f(\mathbf{x}_i) + \xi_i \quad \forall i$$

$$f \sim \mathcal{GP}(f; m(\cdot), k(\cdot, \cdot))$$

$$\xi_i \sim \mathcal{N}(\xi_i; 0, \sigma^2) \quad \forall i$$

y_i : \mathbf{x}_i için ölçülen çıktı değeri

$f(\mathbf{x}_i)$: \mathbf{x}_i için gerçek çıktı değeri

$m(\cdot)$: ortalama fonksiyonu

$k(\cdot, \cdot)$: kovaryans fonksiyonu

ξ_i : ölçüm hatası



Gauss süreci

- Gauss süreci fonksiyonlar üzerinde tanımlanmış bir dağılımdır.
- Gözlemlenen değişkenler beraberce normal dağılım izlemektedir.

$$\begin{bmatrix} f(\mathbf{x}_1) \\ \vdots \\ f(\mathbf{x}_N) \end{bmatrix} \sim \mathcal{N} \left(\begin{bmatrix} f(\mathbf{x}_1) \\ \vdots \\ f(\mathbf{x}_N) \end{bmatrix}; \begin{bmatrix} m(\mathbf{x}_1) \\ \vdots \\ m(\mathbf{x}_N) \end{bmatrix}, \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_1) & \dots & k(\mathbf{x}_1, \mathbf{x}_N) \\ \vdots & \ddots & \vdots \\ k(\mathbf{x}_N, \mathbf{x}_1) & \dots & k(\mathbf{x}_N, \mathbf{x}_N) \end{bmatrix} \right)$$



Gauss süreci

- Ortalama fonksiyonu olarak genelde 0 fonksiyonu kullanılmaktadır.

$$m(\mathbf{x}_i) = 0$$

- Kovaryans fonksiyonu olarak Gauss çekirdeği sıklıkla kullanılmaktadır.

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|_2^2/s^2)$$

$$\mathbf{y} = \mathbf{f} + \boldsymbol{\xi}$$

$$\mathbf{f} \sim \mathcal{N}(\mathbf{f}; \mathbf{0}, \mathbf{K})$$

$$\boldsymbol{\xi} \sim \mathcal{N}(\boldsymbol{\xi}; \mathbf{0}, \sigma^2 \mathbf{I})$$



Gauss süreci

- Bayes teoremini kullandığımızda:

$$p(\mathbf{f}|\mathbf{y}) = \frac{p(\mathbf{y}|\mathbf{f})p(\mathbf{f})}{p(\mathbf{y})}$$

$$\begin{aligned} p(\mathbf{f}|\mathbf{y}) &\propto p(\mathbf{y}|\mathbf{f})p(\mathbf{f}) \\ &\propto p(\mathbf{y} - \mathbf{f})p(\mathbf{f}) \\ &\propto \mathcal{N}(\mathbf{y} - \mathbf{f}; \mathbf{0}, \sigma^2\mathbf{I})\mathcal{N}(\mathbf{f}; \mathbf{0}, \mathbf{K}) \end{aligned}$$



Gauss süreci

- En büyük ardıl olasılık kestirimini kullanarak:

$$\mathbf{f}^* = \arg \max_{\mathbf{f}} p(\mathbf{f}|\mathbf{y}) = \arg \max_{\mathbf{f}} \log p(\mathbf{f}|\mathbf{y})$$

$$\log p(\mathbf{f}|\mathbf{y}) = -\frac{1}{2\sigma^2} \|\mathbf{y} - \mathbf{f}\|_2^2 - \frac{1}{2} \mathbf{f}^\top \mathbf{K}^{-1} \mathbf{f} + \text{constant}$$

- \mathbf{f} değişkenini $\mathbf{K}\boldsymbol{\alpha}$ ile yer değiştirdiğimizde:

$$\log p(\boldsymbol{\alpha}|\mathbf{y}) = -\frac{1}{2\sigma^2} \|\mathbf{y} - \mathbf{K}\boldsymbol{\alpha}\|_2^2 - \frac{1}{2} \boldsymbol{\alpha}^\top \mathbf{K} \boldsymbol{\alpha} + \text{constant}$$



Gauss süreci

- Kısıtsız en iyileme problemi

$$\begin{aligned}\alpha^* &= \arg \max_{\alpha} \log p(\alpha | \mathbf{y}) \\ &= \arg \max_{\alpha} -\frac{1}{2\sigma^2} \left(\mathbf{y}^\top \mathbf{y} - 2\mathbf{y}^\top \mathbf{K}\alpha + \alpha^\top \mathbf{K}\mathbf{K}\alpha \right) - \frac{1}{2} \alpha^\top \mathbf{K}\alpha\end{aligned}$$

- α değişkenine göre türev alıp en iyi değeri bulabiliriz.

$$\alpha^* = (\mathbf{K} + \sigma^2 \mathbf{I})^{-1} \mathbf{y}$$



Gauss süreci

$$\mathbf{a} \sim \mathcal{N}(\mathbf{a}; \boldsymbol{\mu}_a, \boldsymbol{\Sigma}_a)$$

$$\mathbf{b} \sim \mathcal{N}(\mathbf{b}; \boldsymbol{\mu}_b, \boldsymbol{\Sigma}_b)$$

$$\mathbf{a} + \mathbf{b} \sim \mathcal{N}(\mathbf{a} + \mathbf{b}; \boldsymbol{\mu}_a + \boldsymbol{\mu}_b, \boldsymbol{\Sigma}_a + \boldsymbol{\Sigma}_b)$$

- \mathbf{y} and y_* için bileşik olasılık dağılımı

$$\begin{bmatrix} \mathbf{y} \\ y_* \end{bmatrix} \sim \mathcal{N} \left(\begin{bmatrix} \mathbf{y} \\ y_* \end{bmatrix}; \begin{bmatrix} \mathbf{0} \\ 0 \end{bmatrix}, \begin{bmatrix} \mathbf{K} + \sigma^2 \mathbf{I} & \mathbf{k}_* \\ \mathbf{k}_*^\top & k(\mathbf{x}_*, \mathbf{x}_*) + \sigma^2 \end{bmatrix} \right)$$

$$\mathbf{k}_* = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{x}_*) \\ \vdots \\ k(\mathbf{x}_N, \mathbf{x}_*) \end{bmatrix}$$



Gauss süreci

$$\begin{bmatrix} \mathbf{a} \\ \mathbf{b} \end{bmatrix} \sim \mathcal{N}\left(\begin{bmatrix} \mathbf{a} \\ \mathbf{b} \end{bmatrix}; \begin{bmatrix} \boldsymbol{\mu}_a \\ \boldsymbol{\mu}_b \end{bmatrix}, \begin{bmatrix} \boldsymbol{\Sigma}_{aa} & \boldsymbol{\Sigma}_{ab} \\ \boldsymbol{\Sigma}_{ba} & \boldsymbol{\Sigma}_{bb} \end{bmatrix}\right)$$
$$\mathbf{b}|\mathbf{a} \sim \mathcal{N}\left(\mathbf{b}; \boldsymbol{\mu}_b + \boldsymbol{\Sigma}_{ba}\boldsymbol{\Sigma}_{aa}^{-1}(\mathbf{a} - \boldsymbol{\mu}_a), \boldsymbol{\Sigma}_{bb} - \boldsymbol{\Sigma}_{ba}\boldsymbol{\Sigma}_{aa}^{-1}\boldsymbol{\Sigma}_{ab}\right)$$

- y_* değerini kestirmek için aşağıdaki dağılımı kullanabiliriz.

$$y_*|\mathbf{y} \sim \mathcal{N}\left(y_*; \mathbf{k}_*^\top \underbrace{(\mathbf{K} + \sigma^2\mathbf{I})^{-1}\mathbf{y}}_{\boldsymbol{\alpha}}, k(\mathbf{x}_*, \mathbf{x}_*) + \sigma^2 - \mathbf{k}_*^\top (\mathbf{K} + \sigma^2\mathbf{I})^{-1}\mathbf{k}_*\right)$$



Çekirdek tasarımı

- Destek vektör makinesinin eşiz en iyileme problemi dual standart halde şu şekilde yazılabilir.

$$\text{en küçükle } -\mathbf{1}^\top \boldsymbol{\alpha} + \frac{1}{2} \boldsymbol{\alpha}^\top ((\mathbf{y}\mathbf{y}^\top) \odot \mathbf{K}) \boldsymbol{\alpha}$$

$$\text{karar değişkenleri } \boldsymbol{\alpha} \in \mathbb{R}^N$$

$$\text{kısıtlar } \mathbf{y}^\top \boldsymbol{\alpha} = 0$$

$$\mathbf{0} \leq \boldsymbol{\alpha} \leq C\mathbf{1}$$

- En iyilemenin uygun bir şekilde gerçekleşebilmesi için \mathbf{K} matrisinin yarı-kesin pozitif matris olması gerekmektedir.



Çekirdek tasarımı

- $\mathbb{R}^{N \times N}$ kümesinden alınan simetrik bir matris \mathbf{K} eğer bütün özdeğerleri sıfırdan büyük eşit ise yarı-kesin pozitiftir.

$$\boldsymbol{\alpha}^\top \mathbf{K} \boldsymbol{\alpha} \geq 0 \quad \forall \boldsymbol{\alpha} \in \mathbb{R}^N.$$

- Bütün geçerli çekirdek fonksiyonları yarı-kesin pozitif çekirdek matrisleri oluşturmaktadır.

$$\begin{aligned} \boldsymbol{\alpha}^\top \mathbf{K} \boldsymbol{\alpha} &= \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k(\mathbf{x}_i, \mathbf{x}_j) = \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \\ &= \left\langle \sum_{i=1}^N \alpha_i \Phi(\mathbf{x}_i), \sum_{j=1}^N \alpha_j \Phi(\mathbf{x}_j) \right\rangle = \left\| \sum_{i=1}^N \alpha_i \Phi(\mathbf{x}_i) \right\|_2^2 \geq 0 \end{aligned}$$



Çekirdek tasarımı

- k_1 ve k_2 $\mathcal{X} \times \mathcal{X}$ üzerinde tanımlanmış çekirdek fonksiyonları, $\mathcal{X} \subseteq \mathbb{R}^D$, $a \in \mathbb{R}_+$, $f(\cdot)$ \mathcal{X} üzerinde tanımlanmış gerçel değerler üreten bir fonksiyon, k_3 ise $\mathbb{R}^S \times \mathbb{R}^S$ üzerinde tanımlanmış bir çekirdek fonksiyonu ($\Phi: \mathcal{X} \rightarrow \mathbb{R}^S$) ve \mathbf{L} $D \times D$ boyutunda yarı-kesin pozitif bir çekirdek matrisi olmak üzere aşağıdaki fonksiyonlar da geçerli çekirdek fonksiyonlarıdır.

i $k(\mathbf{x}_i, \mathbf{x}_j) = k_1(\mathbf{x}_i, \mathbf{x}_j) + k_2(\mathbf{x}_i, \mathbf{x}_j)$

ii $k(\mathbf{x}_i, \mathbf{x}_j) = ak_1(\mathbf{x}_i, \mathbf{x}_j)$

iii $k(\mathbf{x}_i, \mathbf{x}_j) = k_1(\mathbf{x}_i, \mathbf{x}_j)k_2(\mathbf{x}_i, \mathbf{x}_j)$

iv $k(\mathbf{x}_i, \mathbf{x}_j) = f(\mathbf{x}_i)f(\mathbf{x}_j)$

v $k(\mathbf{x}_i, \mathbf{x}_j) = k_3(\Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j))$

vi $k(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^\top \mathbf{L} \mathbf{x}_j$



Çekirdek tasarımı

- k_1 $\mathcal{X} \times \mathcal{X}$ üzerinde tanımlanmış çekirdek fonksiyonu ve p \mathcal{X} üzerinde tanımlanmış katsayıları pozitif olan bir polinom olmak üzere aşağıdaki fonksiyonlar da geçerli çekirdek fonksiyonlarıdır.

vii $k(\mathbf{x}_i, \mathbf{x}_j) = p(k_1(\mathbf{x}_i, \mathbf{x}_j))$

viii $k(\mathbf{x}_i, \mathbf{x}_j) = \exp(k_1(\mathbf{x}_i, \mathbf{x}_j))$

ix $k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|_2^2 / (2s^2))$



Çekirdek tasarımı

- Tek bir çekirdek fonksiyonu kullanmak yerine çok sayıda çekirdek fonksiyonu kullanabiliriz.

$$k_{\eta}(\mathbf{x}_i, \mathbf{x}_j) = f_{\eta}(\{k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)\}_{m=1}^P)$$

Birleştirme fonksiyonu $f_{\eta}: \mathbb{R}^P \rightarrow \mathbb{R}$ çekirdek fonksiyonlarını $(\{k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)\}_{m=1}^P)$ doğrusal ya da doğrusal olmayan bir yöntemle birleştirebilir.



Çekirdek tasarımı

■ Sabit kurallar

$$k_{\eta}(\mathbf{x}_i, \mathbf{x}_j) = \prod_{m=1}^P k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)$$

$$k_{\eta}(\mathbf{x}_i, \mathbf{x}_j) = \sum_{m=1}^P k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)$$

$$\langle \Phi_{\eta}(\mathbf{x}_i), \Phi_{\eta}(\mathbf{x}_j) \rangle = \begin{pmatrix} \Phi_1(\mathbf{x}_i^1) \\ \Phi_2(\mathbf{x}_i^2) \\ \vdots \\ \Phi_P(\mathbf{x}_i^P) \end{pmatrix}^{\top} \begin{pmatrix} \Phi_1(\mathbf{x}_j^1) \\ \Phi_2(\mathbf{x}_j^2) \\ \vdots \\ \Phi_P(\mathbf{x}_j^P) \end{pmatrix} = \sum_{m=1}^P k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)$$



Çekirdek tasarımı

- Toplam kuralını parametrik bir hale getirebiliriz.

$$k_{\eta}(\mathbf{x}_i, \mathbf{x}_j) = \sum_{m=1}^P \eta_m k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)$$
$$\langle \Phi_{\eta}(\mathbf{x}_i), \Phi_{\eta}(\mathbf{x}_j) \rangle = \begin{pmatrix} \sqrt{\eta_1} \Phi_1(\mathbf{x}_i^1) \\ \sqrt{\eta_2} \Phi_2(\mathbf{x}_i^2) \\ \vdots \\ \sqrt{\eta_P} \Phi_P(\mathbf{x}_i^P) \end{pmatrix}^{\top} \begin{pmatrix} \sqrt{\eta_1} \Phi_1(\mathbf{x}_j^1) \\ \sqrt{\eta_2} \Phi_2(\mathbf{x}_j^2) \\ \vdots \\ \sqrt{\eta_P} \Phi_P(\mathbf{x}_j^P) \end{pmatrix} = \sum_{m=1}^P \eta_m k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)$$

- Doğrusal toplam ($\eta \in \mathbb{R}^P$), konik toplam ($\eta \in \mathbb{R}_+^P$) ve dışbükey toplam ($\eta \in \mathbb{R}_+^P$ ve $\mathbf{1}^{\top} \eta = 1$)



Çekirdek tasarımı

- Çekirdek matrisleri \mathbf{K}_1 ve \mathbf{K}_2 arasındaki hizalanma miktarı şu şekilde yazılır.

$$A(\mathbf{K}_1, \mathbf{K}_2) = \frac{\langle \mathbf{K}_1, \mathbf{K}_2 \rangle_F}{\sqrt{\langle \mathbf{K}_1, \mathbf{K}_1 \rangle_F \langle \mathbf{K}_2, \mathbf{K}_2 \rangle_F}}$$

$$\langle \mathbf{K}_1, \mathbf{K}_2 \rangle_F = \sum_{i=1}^N \sum_{j=1}^N k_1(\mathbf{x}_i, \mathbf{x}_j) k_2(\mathbf{x}_i, \mathbf{x}_j).$$

- Bu değer iki matrisin N^2 boyutunda vektörlere çevrilip aralarındaki açının kosinüsünü hesaplamaya karşılık gelmektedir ($-1 \leq A(\mathbf{K}_1, \mathbf{K}_2) \leq +1$).



Çekirdek tasarımı

- İkili sınıflandırma için ideal çekirdek fonksiyonu:

$$\mathbf{yy}^\top = \begin{bmatrix} y_1y_1 & y_1y_2 & \dots & y_1y_N \\ y_2y_1 & y_2y_2 & \dots & y_2y_N \\ \vdots & \vdots & \ddots & \vdots \\ y_Ny_1 & y_Ny_2 & \dots & y_Ny_N \end{bmatrix}$$

- Bu ideal çekirdeğe benzeyen bir çekirdek oluşturmaya çalışabiliriz.

$$\eta_m = \frac{A(\mathbf{K}_m, \mathbf{yy}^\top)}{\sum_{h=1}^P A(\mathbf{K}_h, \mathbf{yy}^\top)} \quad \forall m$$



Çekirdek tasarımı

- Çekirdek ağırlıklarını birleştirilmiş çekirdekle ideal çekirdek arasındaki hizalanmayı en büyükleyerek seçebiliriz.

$$A(\mathbf{K}_\eta, \mathbf{y}\mathbf{y}^\top) = \frac{\sum_{m=1}^P \eta_m \langle \mathbf{K}_m, \mathbf{y}\mathbf{y}^\top \rangle_F}{N \sqrt{\sum_{m=1}^P \sum_{h=1}^P \eta_m \eta_h \langle \mathbf{K}_m, \mathbf{K}_h \rangle_F}}$$

en büyükle $\sum_{m=1}^P \eta_m \langle \mathbf{K}_m, \mathbf{y}\mathbf{y}^\top \rangle_F$

karar değişkenleri $\boldsymbol{\eta} \in \mathbb{R}_+^P$

kısıtlar $\sum_{m=1}^P \sum_{h=1}^P \eta_m \eta_h \langle \mathbf{K}_m, \mathbf{K}_h \rangle_F = c$



Çekirdek tasarımı

- Çekirdek ağırlıklarını birleştirilmiş çekirdekle ideal çekirdek arasındaki mesafeyi en küçükleyerek de seçebiliriz.

en küçükle $\langle \mathbf{K}_\eta - \mathbf{y}\mathbf{y}^\top, \mathbf{K}_\eta - \mathbf{y}\mathbf{y}^\top \rangle_F$

karar değişkenleri $\boldsymbol{\eta} \in \mathbb{R}_+^P$

$$\text{kısıtlar } \sum_{m=1}^P \eta_m = 1$$

en küçükle $\sum_{m=1}^P \sum_{h=1}^P \eta_m \eta_h \langle \mathbf{K}_m, \mathbf{K}_h \rangle_F - 2 \sum_{m=1}^P \eta_m \langle \mathbf{K}_m, \mathbf{y}\mathbf{y}^\top \rangle_F$

karar değişkenleri $\boldsymbol{\eta} \in \mathbb{R}_+^P$

$$\text{kısıtlar } \sum_{m=1}^P \eta_m = 1$$