
A Survey on Graph Kernels

HAORAN LI 2023/02/24



Kernel Method(1)

- 现实任务中，原始样本空间内也许并不存在一个能正确划分两类样本的超平面，如图6.3所示；
- 对于这样的问题，可以将样本从原始空间映射到一个更高维度的新空间，使得这个样本在新空间内线性可分；
- 映射前： $f(\vec{x}) = \vec{w} \cdot \vec{x} + b$
- 映射后： $f(\vec{x}) = \vec{w} \cdot \vec{\phi(x)} + b$ ，通常求解其对偶问题




图 6.3 异或问题与非线性映射

$$\max_{\vec{\alpha}} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y^{(i)} y^{(j)} \phi(\vec{x}^{(i)}) \phi(\vec{x}^{(j)}), \vec{w} = \sum_{i=1}^m \alpha_i y^{(i)} \phi(\vec{x}^{(i)}), \sum_{i=1}^m \alpha_i y^{(i)} = 0$$

Kernel Method(2)

$$\max_{\vec{\alpha}} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y^{(i)} y^{(j)} \phi(\mathbf{x}^{(i)}) \phi(\mathbf{x}^{(j)}), \vec{w} = \sum_{i=1}^m \alpha_i y^{(i)} \phi(\mathbf{x}^{(i)}), \sum_{i=1}^m \alpha_i y^{(i)} = 0 \quad (28)$$

- 求解(28)需要涉及到计算 $\phi(\mathbf{x}^{(i)})\phi(\mathbf{x}^{(j)})$ ，这通常是困难的，但是如果存在函数 κ :

$$\kappa(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) = \phi(\mathbf{x}^{(i)}) \cdot \phi(\mathbf{x}^{(j)})$$

- 计算 $\phi(\mathbf{x}^{(i)})\phi(\mathbf{x}^{(j)})$ 可以通过计算 $\kappa(\mathbf{x}^{(i)}, \mathbf{x}^{(j)})$ 间接获得，代入(28)求解 $\vec{\alpha}$ ；最终得到

$$f(\mathbf{x}) = \vec{w} \cdot \phi(\mathbf{x}) + b = \sum_{i=1}^m \alpha_i y^{(i)} \phi(\mathbf{x}^{(i)}) \phi(\mathbf{x}) + b = \vec{w}' \phi(\mathbf{x}) + b$$

- 其中 $\vec{w}' = (w'_1, w'_2, \dots, w'_m) = (\alpha_1 y^{(1)} \phi(\mathbf{x}^{(1)}), \alpha_2 y^{(2)} \phi(\mathbf{x}^{(2)}), \dots, \alpha_m y^{(m)} \phi(\mathbf{x}^{(m)}))$

Kernel Method(3)

- 简单来说就是

为了样本线性可分，需要将样本从原始空间映射到一个更高维度的空间；通常这个映射很难直接求得；数学知识告诉我们，只需要求解样本空间中任意两点在映射后的空间中的内积，就可以求解映射后的线性目标函数

- 这个求解任意两点在映射后的空间中的内积的函数称为核函数

Radial Basis Function (RBF) kernel

- 径向基函数 (RBF) 核是一种流行的核函数，用于机器学习和数据分析中聚类、分类和回归等任务
- RBF核也用于基于图的方法中，以衡量图节点之间的相似性或相异性，或者将图数据转换为新的特征空间(feature space)以供后续分析
- 在图的上下文中，RBF 核可以定义如下：给定两个图节点（或节点集），RBF 核测量它们在图中距离的函数作为它们之间的相似性， $K(\mathbf{x}, \mathbf{y}) = e^{-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}}$ ，其中 \mathbf{x} 和 \mathbf{y} 分别表示图节点的特征向量(feature vectors)， $\|\mathbf{x} - \mathbf{y}\|$ 是特征向量之间的距离

Graph Kernel

- A popular approach to learning with graph-structured data is to make use of graph kernels—functions which measure the similarity between graphs—plugged into a kernel machine, such as a support vector machine
- Graph kernels是度量图的相似性(graph similarity)的函数，常用于学习图结构数据的方法
- Graph kernels用于支持向量机(support vector machine)，可以实现图分类(classification)

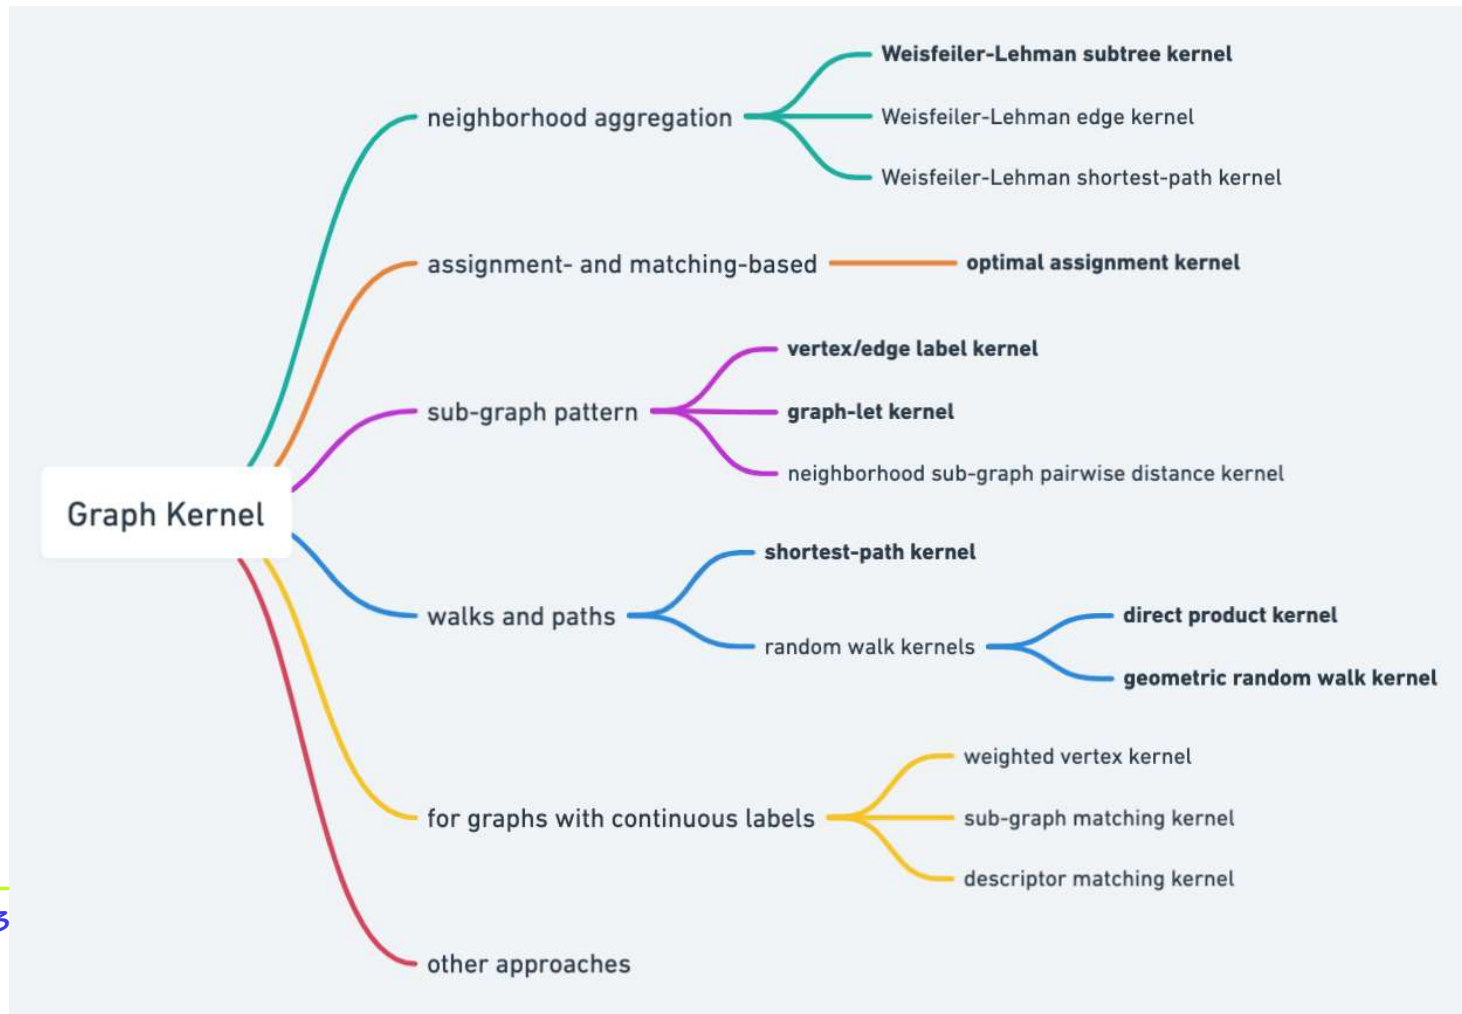
R-convolution Kernel

- 给定两个图 $G_1(V_1, E_1)$ 和 $G_2(V_2, E_2)$, 一种图的分解方式 F
- 分解后结构 $F(G_1) = \{S_{1,1}, S_{1,2}, \dots, S_{1,N_1}\}$, $F(G_2) = \{S_{2,1}, S_{2,2}, \dots, S_{2,N_2}\}$

$$k_{R-conv}(G_1, G_2) = \sum_{n_1=1}^{N_1} \sum_{n_2=1}^{N_2} \delta(S_{1,n_1}, S_{2,n_2})$$

- 其中 $\delta(S_{1,n_1}, S_{1,n_2})$ 在 S_{1,n_1} 和 S_{1,n_2} 同构时为 $\mathbf{1}$ (近似结果), 否则为 \mathcal{O}

Graph Kernel Approaches




1-d Weisfeiler-Lehman subtree kernel

- 如果两个图由具有相似邻域的顶点组成，即它们具有相似的局部结构，则它们被认为是相似的。

$$l^i(v) = \text{relabel}(l^{i-1}(v), \text{sort}(\{l^{i-1}(u) | u \in N(v)\}))$$


Original labels
 $i = 0$



$\Sigma = \{A, B\}$

$\Sigma_0 = \{A, B\}$


Relabeled
 $i = 1$



$\Sigma = \{A, B, C, D, E\}$

$\Sigma_1 = \{C, D, E\}$

Relabeled
 $i = 2$



$\Sigma = \{A, B, C, D, E, F, G, H, I\}$

$\Sigma_2 = \{F, G, H, I\}$

...

for graph G , feature vector of all h iterations
 $\phi_{WL}(G) = (\phi_{\sigma_1^0}^0(G), \dots, \phi_{\sigma_{|\Sigma_0|}^0}^0(G), \dots, \phi_{\sigma_1^h}^0(G), \dots, \phi_{\sigma_{|\Sigma_h|}^0}^0(G))$

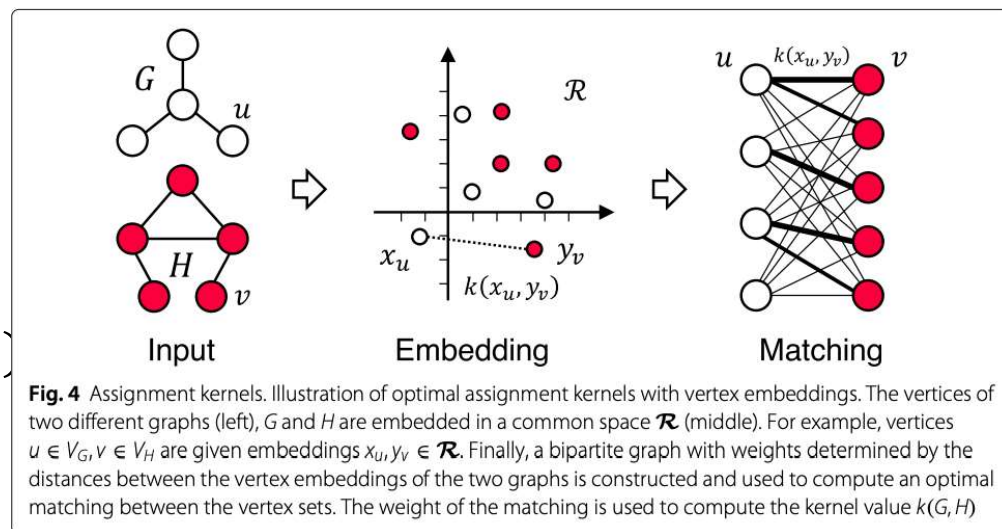
Weisfeiler-Lehman subtree kernel for h iterations
 $k_{WL}(G, H) = \phi_{WL}(G) \cdot \phi_{WL}(H)$

Optimal assignment kernel

图 X, Y 具有结构: $X = \{x_1, \dots, x_n\}, Y = \{y_1, \dots, y_n\}, x_i, y_j \in \mathcal{R}$

定义base kernel, $k: \mathcal{R} \times \mathcal{R} \rightarrow \mathbb{R}, \mathbb{R}$ is real number set

Optimal assign kernel: $K_A(X, Y) = \max_{\pi \in \Pi} \sum_{i=1}^n k(x_i, y_{\pi(i)})$




Vertex/Edge label kernel

$$K_{VL}(G, H) = \sum_{u \in V(G)} \sum_{v \in V(H)} k(l(u), l(v))$$

- Base kernel k is the quality indicator function
- 缺点是忽略了结构和标签之间的相互作用，并且对于未标记的图几乎完全没有作用
- Instead of viewing graphs as bags of vertices or edges, we may view them as bags of subgraph patterns. To this end, Shervashidze et al. introduced a kernel based on **counting occurrences of subgraph patterns of a fixed size**

Graphlet kernel

- 给定 k 个顶点，列举出所有的同构类型 σ_i , $1 \leq i \leq N$ ，即不同类型的图都是异构的
- 计算图 G 中同构类型 σ_i 的出现次数 $\phi(G)_{\sigma_i}$,
 $feature\ map\ \phi_{GR}(G) = (\phi(G)_{\sigma_1}, \dots, \phi(G)_{\sigma_N})$
- Graphlet kernel: $k_{GR}(G, H) = \phi_{GR}(G) \cdot \phi_{GR}(H)$



Shortest-path Kernel

$$k_{SP}(G, H) = \sum_{(u,v) \in V(G)^2, u \neq v} \sum_{(w,z) \in V(H)^2, w \neq z} k((u, v), (w, z))$$

$$k((u, v), (w, z)) = k_L(l(u), l(w)) \cdot k_L(l(v), l(z)) \cdot k_D(d(u, v), d(w, z))$$


- k_L 是用于比较顶点标签(vertex label)的核
- k_D 是用于比较两个顶点最短路径距离的核

Direct Product of Graphs

$G \times H = (\mathcal{V}, \mathcal{E})$ 图 $G = (V, E), H = (V', E')$,
图的直积

$$\mathcal{V} = \{(v, v') \in V \times V' \mid l(v) = l(v')\}$$

$$\mathcal{E} = \{((u, u'), (v, v')) \in \mathcal{V} \mid (u, v) \in E \wedge (u', v') \in E' \wedge l((u, v)) = l((u', v'))\}$$



Direct Product & Geometric Random Walk kernel

$$G \times H = (\mathcal{V}, \mathcal{E})$$

- The direct product kernel is then defined as

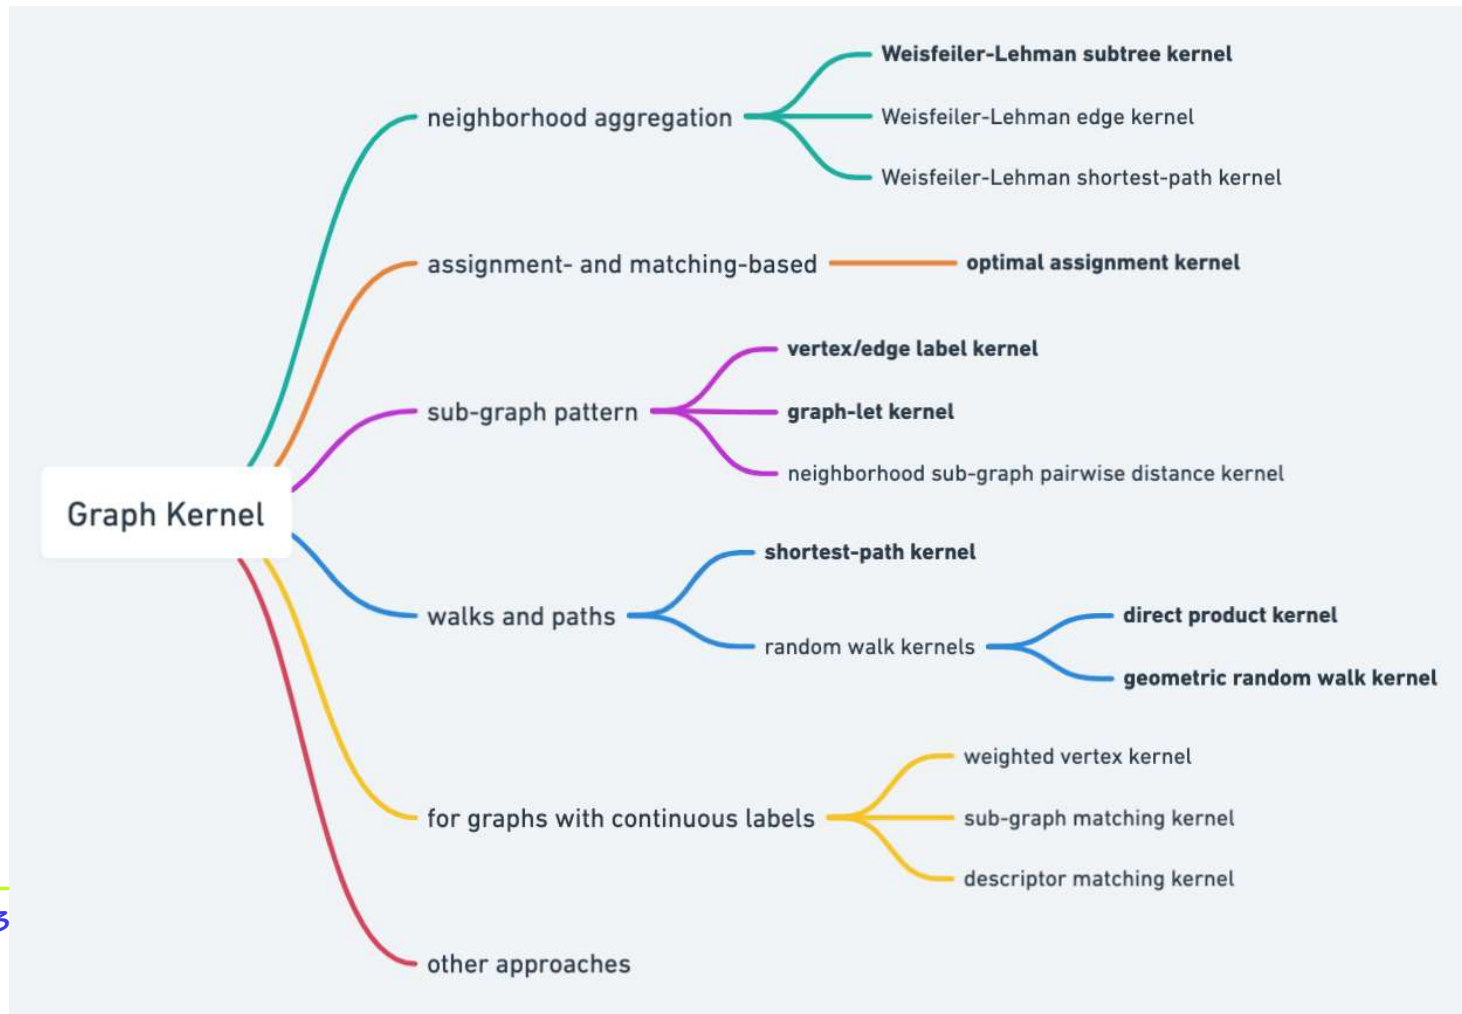
$$K_{\text{RW}}(G, H) = \sum_{i,j=1}^{|\mathcal{V}|} \left[\sum_{l=0}^{\infty} \lambda_l \mathbf{A}_{\times}^l \right]_{ij}$$

- \mathbf{A}_{\times} 表示直积图的邻接矩阵
- λ_l 需要使得级数收敛

- The geometric random walk kernel is

$$K_{\text{GRW}}(G, H) = \sum_{i,j=1}^{|\mathcal{V}|} [(\mathbf{I} - \gamma \mathbf{A}_{\times})^{-1}]_{ij}$$

Graph Kernel Conclusion



Expressivity

- Complete graph kernel对应的feature map是一个单射(injection)
- 如果一个graph kernel不是complete的, 则表示存在两个非同构(non-isomorphic)的图 G, H , 使得 $\phi(G) = \phi(H)$, 即这两个图不能被此kernel区分
- 特别是Oneto等人, 从统计的角度研究了图内核的表达性

Applications
