

图卷积神经网络

author: riverspace@yeah.net



D
D
D
D
D



1. ~~二维~~ 信号的拉普拉斯算子

哈密顿算子: $\nabla \equiv \frac{\partial}{\partial x} \vec{i} + \frac{\partial}{\partial y} \vec{j} + \frac{\partial}{\partial z} \vec{k}$

拉普拉斯算子: $\Delta = \nabla \cdot \nabla = \nabla^2$

1. 拉普拉斯算子表示梯度变化量的汇总

2. 一维信号的拉普拉斯算子与傅里叶变换

函数 $g(t) = e^{-j\omega t}$ 的拉普拉斯变换为:

$$\Delta g(t) = \Delta(e^{-j\omega t}) = \frac{d g'(t)}{dt} = -j\omega \frac{d(e^{-j\omega t})}{dt} = -\omega^2 (e^{-j\omega t})$$

∴ 函数 $g(t) = e^{-j\omega t}$ 是拉普拉斯算子的特征函数


∴ 函数 $f(t)$ 的傅里叶变换可视为一维拉普拉斯算子特征函数的展开:

$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt$$

3. 二维离散信号的拉普拉斯变换

$$\Delta f = \text{div } \nabla f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}$$

$$= [f(x+1, y) - f(x, y)] + [f(x-1, y) - f(x, y)] + [f(x, y+1) - f(x, y)] + [f(x, y-1) - f(x, y)]$$



4. 图的拉普拉斯变换:

边无权重时: $\Delta f_i = \sum_{j \in N_i} (f_i - f_j)$

边有权重时: $\Delta f_i = \sum_{j \in N_i} W_{ij} (f_i - f_j)$

$$= \sum_{j \in N_i} W_{ij} f_i - \sum_{j \in N_i} W_{ij} f_j$$

$$= d_i f_i - W_{i, \cdot} f$$

$$\therefore \Delta f = \begin{pmatrix} \Delta f_1 \\ \vdots \\ \Delta f_N \end{pmatrix} = \begin{pmatrix} d_1 f_1 - W_{1, \cdot} f \\ \vdots \\ d_N f_N - W_{N, \cdot} f \end{pmatrix} = \begin{pmatrix} d_1 & & \\ & \ddots & \\ & & d_N \end{pmatrix} f - \begin{pmatrix} W_{1, \cdot} \\ \vdots \\ W_{N, \cdot} \end{pmatrix} f$$

$$= Df - Wf = \underbrace{L}_{\text{拉普拉斯矩阵}} f \quad (\text{定义})$$

$$= (D - W) f$$



1. 图的傅里叶变换

图的傅里叶变换定义为图在拉普拉斯矩阵特征向量上的谱特征展开, 即

$$\hat{f}(\lambda) = \begin{pmatrix} u_{11} & \dots & u_{1n} \\ \vdots & \ddots & \vdots \\ u_{m1} & \dots & u_{mn} \end{pmatrix} \begin{pmatrix} f_1 \\ f_2 \\ \vdots \\ f_n \end{pmatrix} = U^T f$$

其中, 矩阵 U 的列向量是拉普拉斯矩阵的特征向量, 即

$$LU = U\Lambda$$

矩阵 Λ 是由拉普拉斯矩阵特征值组成的对角矩阵, 即

$$\Lambda = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_n \end{pmatrix}$$

2. 图的傅里叶逆变换

$$\because UU^T = I$$

$$\therefore \text{图的傅里叶逆变换 } f = UU^T \hat{f} = U \hat{f}$$

$$\text{其中 } \hat{f}(\lambda) = U^T f$$

3. 图的卷积变换:

① 在坐标系变换中, 傅里叶变换有

$$f(x) * g(x) = F^{-1}(F(f(x)) \cdot F(g(x)))$$

$$F(f(x) * g(x)) = F(f(x)) \cdot F(g(x))$$

② 在图变换中, 傅里叶变换有:

~~$$x * y = F_G^{-1}(F_G(x) \cdot F_G(y))$$~~

$$x * y = F_G^{-1}(F_G(x * y))$$

$$F_G(x * y) = \langle F_G(x), F_G(y) \rangle$$



③. 图上的卷积定义:

设 x 是定义在图 $G(E, V)$ 上的信号, g 是定义在图上的卷积核函数.
 则 x 与 g 的卷积:

$$y = x *_G g = U((U^T x) \circ (U^T g))$$

其中, \circ 表示哈达玛积.

$\because U^T g$ 为未知系数, 可将其系数化为 $U^T g = \theta$.

$$(2) \quad y = x *_G g$$

$$= U((U^T g) \circ (U^T x))$$

其中, 记

$$= U g_0 U^T x$$

$$g_0 = \text{diag}(U^T g) = \text{diag}(\theta)$$

$$= U \text{diag}(\theta) U^T x$$

$$\text{注: } \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \circ \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} x_1 & & \\ & \ddots & \\ & & x_n \end{bmatrix} y$$

进一步, 将 g_0 看成关于拉普拉斯矩阵 L 特征值的函数, 即 $g_0 = g(\lambda)$.

$$(2) \quad y = x *_G g = U g_0(\lambda) U^T x \quad \dots (*)$$

(*) 式计算复杂度较高, 可用切比雪夫多项式近似计算.

设 λ_{\max} 代表拉普拉斯矩阵的最大特征值, 令

$$\tilde{\lambda} = \frac{2\lambda}{\lambda_{\max}} - 1_N \quad (\text{此时对角元值界于} [-1, 1] \text{间}),$$

则 $g_0(\lambda)$ 近似为如下截断的 $k+1$ 阶切比雪夫多项式:

$$g_0(\lambda) = \sum_{k=0}^{k-1} \alpha_k T_k(\tilde{\lambda})$$



④ 离散余弦的实现

• 切比雪夫序列:

具有度 $n > 0$ 的切比雪夫序列定义为

$$T_n(x) = \cos(n \arccos(x)), \quad x \in [-1, 1]$$

或表示为

$$T_n(x) = \cos(n\theta), \quad x = \cos\theta \in [-1, 1]$$

∴ 切比雪夫序列可表示为如下递归形式:

$$T_n(x) = 2xT_{n-1}(x) - T_{n-2}(x)$$

其中, $T_0(x) = 1$, $T_1(x) = \cos(\theta) = x$

• 图卷积结果:

$$\text{由式子 } g_\theta(\lambda) = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\lambda})$$

可得图卷积的结果表示为:

$$y = U g_\theta U^T x$$

$$= U \left(\sum_{k=0}^{K-1} \theta_k T_k(\tilde{\lambda}) \right) U^T x$$

$$= \left(\sum_{k=0}^{K-1} \theta_k U T_k(\tilde{\lambda}) U^T \right) x$$

$$= \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L}) x$$

• 图卷积的快速计算方法:

设 $\tilde{x}_k = T_k(\tilde{L}) x$, 则由关系式:

$$T_{k+1}(x) = 2xT_k(x) - T_{k-1}(x)$$

$$\text{可得: } \tilde{x}_k = 2\tilde{L}\tilde{x}_{k-1} - \tilde{x}_{k-2}$$

$$\text{由此可得: } y = g_\theta(\tilde{L}) x = (\tilde{x}_0, \dots, \tilde{x}_{K-1}) \theta$$

其中, $\theta = \begin{pmatrix} \theta_0 \\ \vdots \\ \theta_{K-1} \end{pmatrix}$ 是系数 θ_k 组成的向量.

