

支持向量机预测原理

支持向量机 (Support Vector Machine, SVM) 预测算法根据给定的训练样本 $S = \{(x_1, y_1), \dots, (x_l, y_l)\} \subset R^n \times R$, 可以构建回归函数:

$$y_i = w^T \phi(x_i) + b + e_i \quad (1)$$

其中, e_i 为误差。定义损失函数为:

$$I(y, f(x)) = (y - f(x))^2 = e^2 \quad (2)$$

其中, y 为实际值, $f(x)$ 为预测值。

最小二乘支持向量机 (LSSVM) 根据结构最小化原理, 定义其风险函数为:

$$J_l = \frac{1}{2} \|\omega\|^2 + \gamma \sum_{i=1}^l e_i^2 \quad (3)$$

由此推得原始最优化问题:

$$\min J_l(\omega, e) = \frac{1}{2} \|\omega\|^2 + \gamma \sum_{i=1}^l e_i^2 \quad (4)$$

其中, γ 为正实数, 表示惩罚系数。它能够调节模型精度与模型复杂度的关系, 在两者之间寻求一种折中, 使所训练出来的模型具有比较强的泛化能力。
构造新的拉格朗日乘子并置零:

$$\begin{cases} \frac{\partial L}{\partial \omega} = 0 \rightarrow \omega = \sum_{i=1}^l \alpha_i \phi(x_i) \\ \frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^l \alpha_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = \gamma e_i \\ \frac{\partial L}{\partial \alpha_i} = 0 \rightarrow b = y_i - \omega^T \phi(x_i) - e_i \\ i = 1, \dots, l \end{cases} \quad (5)$$

消去 ω 和 e_i , 得到以下方程:

$$\begin{bmatrix} 0 & I_v^T \\ I_v & \Omega + D_\gamma^{-1} \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

其中, $I_v = [1, 1, \dots, 1]^T$, 对角阵 $D_\gamma = \text{diag}[\gamma, \gamma, \dots, \gamma]$, $y = [y_1, y_2, \dots, y_l]^T$,

$\alpha = [\alpha_1, \alpha_2, \dots, \alpha_l]^T$, 矩阵 Ω 的各元素为

$$\Omega_{ij} = \phi(x_i)^T \phi(x_j) = K(x_i, x_j) \quad (7)$$

其中, $K(x, x_i)$ 是满足 Mercer 条件的核函数, 它把原始空间中的特征量映射到高维空间中去, 将原始空间中的二次规划问题转到高维空间的线性问题中去解决。径向基核函数的泛化能力强, 结构相对简单, 因此选用径向基函数作为预测问题的核函数, 其表达式为:

$$k(x, x^*) = \exp\left(-\frac{\|x - x^*\|^2}{2\sigma^2}\right) \quad (8)$$

对式 (6) 进一步求解得到变量 α 与 b , 则预测模型为:

$$y(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b \quad (9)$$

SVM 预测流程如图 1 所示。




图 1 预测流程图

惩罚系数 γ 和径向基核函数中核参数 σ 的取值, 直接决定 SVM 预测的性能,

因此采取参数寻优方法优化支持向量机功率预测的效果。通常采用网格法找出惩罚系数和核参数，在模型上用交叉验证的方式验证参数的预测误差，找出误差最小的那对参数，即为最优解。