

文章编号: 1003-207(2005)04-0129-06

农产品销量预测的支持向量机方法

杜小芳^{1,2}, 张金隆²

(1. 武汉理工大学, 湖北 武汉 430070; 2. 华中科技大学管理学院, 湖北 武汉 430074)

摘要: 运用支持向量机(Support Vector Machine, SVM)智能预测方法对农产品的消费需求进行动态预测。为提高农产品销量预测精度,充分考虑了农产品供需随天气变化、气候条件、节假日等因素的影响而动态变化的情况,将这些影响因素纳入农产品销量预测中,运用模糊理论进行模糊化处理;在此基础上提出以支持向量机方法为主、多方法融合为辅的智能预测系统,对农产品销量进行动态预测。实际算例验证了这一智能预测系统的精确性。

关键词: 支持向量机; 农产品; 销量预测; 模糊理论; 核函数

中图分类号: F830 文献标识码: A

1 引言

农产品属生鲜易腐产品,具有严格的保质期限制,合理的农产品采购决策来源于对农产品市场需求的准确预测。以往的农产品需求预测通常采用由历史情况推测未来需求的经验方法,或采用时间序列分析方法、回归分析法、人工神经网络方法等等,这些预测方法本身存在一定的局限性。

经验分析方法^{[1][2]}依赖以往的经验,不能适应未来需求的变化。时间序列分析方法^{[3][4]}根据变量自身过去的变化规律来预测未来的变化,这种方法要求时间序列具有稳定的变化趋势,而对于不确定需求的预测则可信度较差。回归分析法^{[5][6]}是一种建立在数理统计理论基础上的统计预测方法,它寻求需求量与一个或多个自变量之间的线性关系,此方法需要有大量数据,数据少则难以找出统计规律。另外,回归分析法所得到的回归预测方程往往只能考虑少数几种主要影响因素,而略去了许多未考虑的因素,影响了预测的准确性。近年来,人工神经网络方法^{[7][8][9]}在预测领域得到广泛应用,但神经网络模型采用最速下降法来搜索最优解,它不能保证神经网络的误差函数收敛到全局最优解。而且,神经网络存在过学习(over-fitting)问题,也就是在训练神经网络过程中,过分强调克服学习误差,

而过小的训练误差反而导致推广能力下降,使得未来输出进行正确预测的能力下降。以上这些方法均难以考虑动态因素对农产品需求的影响,难以解决本质非线性的问题。

而以统计学习理论、Huber 稳健回归理论和 Wolfe 对偶规划理论为基础的支持向量机(Support Vector Machine, SVM)方法具有拟合精度高、推广能力强和全局最优等特点,为解决有限样本情况下的机器学习问题提供了有力的理论基础和行之有效的解决方法^{[10][11]}。SVM 方法基于结构风险最小化原理,而不是基于经验风险最小化原理,避免了人工神经网络方法的过学习现象,对未来样本有较好的泛化性能;它等价于解决一个线性约束的二次规划问题,因此能取得全局最优解。

SVM 方法最初用来解决模式识别问题^[12],但随着 Vapnik 的 ϵ 不敏感损失函数的引入, SVM 已扩展为解决非线性回归估计问题^{[13][14]}。在 1998 年, K. - R. Muller et al 将 SVM 应用到时间序列的预测中^[15],并和径向基函数的神经网络作了比较,结果显示 SVM 具有极好的预测性能。 Gestel T. V. et al 把最小二乘支持向量机(LS-SVM)和贝叶斯体系结合起来以预测非线性时间序列,并将其应用到金融时间序列的预测,在证据体系下,他们设计的 LS-SVM 回归在金融时间序列预测中是成功的^[16]。纪延光等^[17]将支持向量机技术应用于 R&D 项目过程质量度量,在小样本基础上,构建 R&D 项目实施过程中阶段质量状态的度量模型,进行 R&D 项目过程质量状态评估,实证研究结果表明该方法可很好地应用于 R&D 项目的过程质量

收稿日期: 2004-11-11; 修订日期: 2005-07-27

基金项目: 湖北省科技攻关资助项目(2002AA401D01)

作者简介: 杜小芳(1973-),女(汉族),湖北省公安县人,华中科技大学管理学院博士研究生,武汉理工大学讲师,研究方向: 信息资源管理、物流管理。

管理。

由于影响农产品需求预测的因素较多,且实时变化,因此难以用单一模型描述,用简单算法解决。针对 SVM 方法拟合精度高、推广能力强和全局最优等特点,本文首次将支持向量机方法应用于农产品销量预测中,并充分考虑农产品供需随自然条件、社会环境因素等影响而动态变化的情况,将这些影响因素纳入农产品需求预测中,运用模糊理论进行模糊化处理,在此基础上提出以支持向量机方法为主、多方法融合为辅的智能预测系统,对农产品销量进行动态预测。

2 用于回归估计的 SVM 方法

SVM 方法的基本思想可以概括为:首先通过非线性变换将输入向量 x 映射到一个高维空间 Z , 然后在这个新空间 Z 中求取最优线性分类面,而这种非线性变换是通过定义适当的内积函数实现的。^[13]

给定一数据集 $G = \{(x_i, d_i)\}_{i=1}^n$, 其中 x_i 是输入向量, d_i 是期望值, n 是训练样本个数。SVM 采用下式来估计函数:

$$y = f(x) = w\phi(x) + b \tag{1}$$

式中 $\phi(x)$ 是从输入空间到高维特征空间的非线性映射, w 和 b 是系数, 它们由最小化风险函数 $R(C)$ 来估计:

$$\text{Minimize: } R(C) = \frac{1}{2} \|w\|^2 + C \frac{1}{n} \sum_{i=1}^n L_{\varepsilon}(d_i, y_i) \tag{2}$$

$$L_{\varepsilon}(d, y) = \begin{cases} |d - y| - \varepsilon & |d - y| \geq \varepsilon \\ 0 & |d - y| < \varepsilon \end{cases} \tag{3}$$

ε 是给定的参数, 式(3)中 $L_{\varepsilon}(d, y)$ 是 ε 不敏感损失函数, 此损失函数在特征空间中确定一个以平面 $y = f(x)$ 为中心, 厚为 2ε 的薄板区域。当样本落入该区域时, 意味着预测值和实际值之间的差别小于 ε , 则损失等于 0; 当样本落入该区域外时, 对其进行线性惩罚。 $\frac{1}{2} \|w\|^2$ 是对函数面的量度, C 是常量, 用来平衡模型复杂性项 $\frac{1}{2} \|w\|^2$ 和训练误差项的权重参数。

为了寻找系数 w 和 b , 需要引入松弛变量 ξ_i 和 ξ_i^* , 使式(4)最小化:

$$\text{Minimize: } R(w, \xi_i^{(*)}) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i$$

$$+ \xi_i^{(*)} \tag{4}$$

$$\text{Subjected to: } \begin{cases} d_i - w\phi(x_i) - b \leq \varepsilon + \xi_i \\ w\phi(x_i) + b - d_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

根据格拉朗日 (Lagrange) 对偶原理, 引入对偶变量, 这些变量应满足非负条件, 即 $\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0$ 。构造 Lagrange 函数 L 如下:

$$L = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - d_i + w\phi(x_i) + b) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + d_i - w\phi(x_i) - b) - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) \tag{5}$$

在优化问题中, Lagrange 函数有一个鞍点, 根据鞍点条件, L 函数相对于原始变量 (w, b, ξ_i, ξ_i^*) 的偏倒数为 0, 即:

$$\partial_b L = \sum_{i=1}^n (\alpha_i^* - \alpha_i) = 0 \tag{6}$$

$$\partial_w L = w - \sum_{i=1}^n (\alpha_i - \alpha_i^*) \phi(x_i) = 0 \tag{7}$$

$$\partial_{\xi_i^*} L = C - \alpha_i^{(*)} - \eta_i^{(*)} = 0 \tag{8}$$

将式(6)、(7)、(8) 代入(5), 利用 Wolfe 对偶技巧, 得到如下优化问题, 式中 $\langle \square, \square \rangle$ 表示特征空间中的点积:

$$\max_{R(\alpha_i, \alpha_i^*)} : - \frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle \phi(x_i), \phi(x_j) \rangle - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n d_i (\alpha_i - \alpha_i^*) \tag{9}$$

$$\text{st: } \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i, \alpha_i^* \in [0, C] \end{cases}$$

对于非线性回归问题, 可以通过构造新的特征向量, 把问题转换到一个新的空间中, 这需要设法将非线性问题通过非线性变换转化为另一个高维空间中的线性问题。在这个变换空间中, 只需要定义变换后的内积运算, 甚至没必要知道采用的非线性变换的形式, 这种算法克服了可能导致的维数灾难问题, 并且降低了计算复杂度。统计学习理论指出, 根据 Hilbert-Schmidt 原理, 只要一种运算满足 Mercer 条件, 它就可以作为这里的内积使用。在寻优目标函数中, 采用适当的内积函数 $K(x_i, x_j)$ 就可以实现某一非线性变换后的线性回归^[18]。支持向量机

回归方法的殊效在于, 通过引入点积核函数 $K(x_i, x_j)$ 和利用 Wolfe 对偶技巧避开了维数灾难和目标函数不可微问题。因此, 目标函数变为:

$$\begin{aligned} \max_{R(\alpha_i, \alpha_i^*)}: & -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i, x_j) - \\ & \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n d_i (\alpha_i - \alpha_i^*) \quad (10) \\ \text{st: } & \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i, \alpha_i^* \in [0, C] \end{cases} \end{aligned}$$

相应的回归函数式(1)可直接写为:

$$y = f(x, \alpha_i, \alpha_i^*) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (11)$$

3 基于 SVM 方法的农产品销量预测

3.1 指标选择

农产品销售预测是一个复杂的多变量预测问题, 它可以被看成一个函数回归问题。销售量 y 为函数的输出值, 而相应的影响销售量的因素如: 历史销售量、温度信息、气象信息、节假日信息、季节信息等, 作为函数输入值 x 。问题的最终目标是寻找一个有良好推广能力的从影响销售量的因素到销售量的映射。

利用支持向量机方法进行农产品销量预测时, 分别按照历史销售量、销售量相关数据(如温度、日期类型等)形成 11 类训练、预测样本, 样本表示为: $\tilde{X} = [A_{d-1}, A_{d-2}, A_{d-7}, w_{kd}, w_{kd-1}, T_{maxd}, T_{mind}, T_{max(d-1)}, T_{min(d-1)}, w_d, w_{d-1}]$ 。

其中: A_{d-1} : 预测日前一天的销售量

A_{d-2} : 预测日前前天的销售量

A_{d-7} : 预测日前一个星期本天的销售量

w_{kd} : 预测日的星期类型(周末或工作日)

w_{kd-1} : 预测日前一天的星期类型

T_{maxd} : 预测日当天的最高温度

T_{mind} : 预测日当天的最低温度

$T_{max(d-1)}$: 预测日前一天的最高温度

$T_{min(d-1)}$: 预测日前一天的最低温度

w_d : 预测日的天气情况(晴天、雨天等)

w_{d-1} : 预测日前一天的天气情况

3.2 影响因素的模糊化处理

这里对农产品需求预测的影响因素, 如星期类

型、天气及温度情况进行了模糊化处理, 经过隶属函数转化为模糊量, 隶属函数的设计会影响预测的精度和系统的稳定性。这里对星期类型的隶属函数采用半矩形分布^[19]; 对温度的隶属函数采用梯形分布^[20]; 对天气情况, 则采用天气-温度量化系数法^[21]。

星期类型的隶属函数分布: (1) 对工作日的隶属度函数为 $\mu_{d1} = \{1, 0\}$, 1 表示周一至周五等五天工作日, 0 表示周六和周日; (2) 对双休日的隶属度函数为 $\mu_{d2} = \{0, 1\}$, 0 表示周一到周五等五天工作日, 1 表示周六和周日。

温度的隶属度函数分布如下:

①对低温的隶属度函数采用偏小型梯形分布:

$$u_{t1} = \begin{cases} 0 & t > 10 \\ \frac{10-t}{10-0} & 0 \leq t \leq 10 \\ 1 & t < 0 \end{cases}$$

②对中温的隶属度函数采用中间型梯形分布:

$$u_{t1} = \begin{cases} 0 & t > 25 \\ \frac{t-5}{15-5} & 5 \leq t \leq 15 \\ \frac{25-t}{25-15} & 15 \leq t \leq 25 \end{cases}$$

③对高温的隶属度函数采用偏大型梯形分布:

$$u_{t1} = \begin{cases} 0 & t < 20 \\ \frac{t-20}{40-20} & 20 \leq t \leq 40 \\ 1 & t > 40 \end{cases}$$

将同类型日的最高温度 T_{max} 带入以上 3 个公式中, 可分别求出其对于低温、中温、高温 3 个状态的隶属度。根据隶属度最大原则, $T_{max} = \max\{T_{max1}, T_{max2}, T_{max3}\}$, 并可知 T_{max} 所属的模糊集。对于最低温度 T_{min} , 可采用同样的方法求出它的 3 个状态隶属度及其取值。根据温度所属的模糊集, 量化天气情况。低温 = {晴多云 阴 雨} = {0.05 0.25 0.45 0.95}; 中温 = {晴 多云 阴 雨} = {0.0 0.2 0.4 0.9}; 高温 = {晴 多云 阴 雨} = {0.1 0.3 0.5 1.0}。

3.3 核函数构造

SVM 方法中, 核函数 $K(x_i, x_j)$ 的选择决定了特征空间的结构, 核函数的值等于两个向量 x_i 和 x_j 在其特征空间 $\varphi(x_i)$ 和 $\varphi(x_j)$ 的内积, 即 $K(x_i, x_j) = \varphi(x_i) \times \varphi(x_j)$ 。任何函数只要满足 Mercer 条件, 都可用作核函数, 采用不同的函数作为核函数, 可以构造实现输入空间中不同类型的非线性决策面的学

习机器。核函数的选取对预测精度有较大影响,通过自适应和交叉验证的方法,选取指数型径向基函数 $erbf(\text{exponential radial basis function})$ 作为农产品销售量预测的核函数,即 $K(x_i, x_j) = \exp(-|x_i - x_j| / 2\delta^2)$, δ^2 是核的宽度参数。

3.4 损失函数选取

损失函数在特征空间中确定了一个以平面 $f(x)$ 为中心,厚为 2ε 的薄板区域,这个损失函数必须进行适当修改,使之包含一个距离的度量,这里选取二次损失函数 (Quadratic Loss Function), $L_{quad}(f(x) - y) = (f(x) - y)^2$ 作为农产品销售预测的损失函数,对应于最小平方误差标准。

4 实例分析

支持向量机的训练本质上是解一个二次规划问题,对这个二次规划问题,虽然有一些经典的算法诸如对偶方法、内点算法等,但是当训练集规模很大时,这些算法将面临着维数灾难。后来,一些学者提出了相应的改进算法,如 V. Vapnik 等提出的 Chunking 算法^[10], Platt J. C. 提出的 SMO 算法等^{[22][23]},不同程度的提高了收敛速度。文中采用改进的 SVM 训练算法来实现农产品销售量预测。选择每天的预测误差 Error、平均百分误差 e_{mapc} 和预测准确度 A_L 为性能指标,定义为:

$$Error = \left| \frac{A(i) - F(i)}{A(i)} \right| \times 100\%$$

$$e_{mapc} = \frac{1}{n} \sum_{i=1}^n \left| \frac{A(i) - F(i)}{A(i)} \right| \times 100\%$$

$$A_L = [1 - \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{A(i) - F(i)}{A(i)} \right)^2}] \times 100\%$$

其中, $A(i)$ 和 $F(i)$ 分别表示实际销售量和预测销售量。

采用 SVM 方法进行农产品销售量预测的步骤为:

(1) 对历史数据进行平滑预处理和归一化处理,对销售相关数据进行量化处理,对天气、温度、节假日数据等进行模糊化处理,然后形成样本集;

(2) 用训练样本建立如式(10)的目标函数;

(3) 利用改进的 SVM 训练算法来求解式(10),得到解 α_i 和 α_i^* , $i = 1, \dots, n$;

(4) 将得到的拉格朗日乘子解代入式(11)中,再利用预测样本对未来销售量进行预测。

分别用 SVM 方法和 RBF 神经网络方法对某超市某一类农产品的销售量进行预测,并将两者预测结果进行比较。两种方法的预测曲线与实际曲线如图 1 所示,图中可以看出 SVM 的预测曲线与实际值贴近,而 RBF 神经网络方法的预测精度要比 SVM 的预测精度差。




图 1 SVM 预测值、RBF 神经网络预测值与实际销售量的比较

预测中选取一个星期,以日预测误差 Error 为性能指标,比较 SVM 方法和 RBF 神经网络方法的预测结果(如表 1 所示),由表中数据可以看出 SVM 方法的预测误差较小。

表 1 一周预测结果比较

预测误差 \ 星期	星期一		星期二		星期三		星期四		星期五		星期六		星期日	
	SVM	RBF	SVM	RBF	SVM	RBF	SVM	RBF	SVM	RBF	SVM	RBF	SVM	RBF
Error(100%)	0.03	0.3	0.09	4.3	0.04	0.9	0.03	0.1	0.29	1.3	0.00	1.8	0.11	0.1

SVM 方法进行销售量预测时,参数 ε 对预测精度影响甚小,实验中取 $\varepsilon = 0.01$ 。参数 δ 、 C 的选取对结果影响较大,选取预测准确度 A_L 和平均百分误差 e_{mapc} 为性能指标进行实验发现,当将 δ 固定在 1, C 在 0.1~100 范围内变化时,随着 C 值的增加,预测精度增加,在 0.1-1 范围内增加较明显;当 C

大于 100 后,预测精度高且对 C 的变化不敏感;而当 C 小于 0.1 以后,预测精度变得很差。当将 C 固定在 $C = 100$, 改变 δ 值时发现 $\delta = 1$ 时预测精度较高,当 $\delta > 1$ 或者 $\delta < 1$ 时,预测精度均变差。表 2 反映了预测结果与参数的关系。

表2 参数对预测结果的影响

	$\delta = 1$						$C = 100$			
	C						δ			
	0.1	0.5	1	100	500	100	0.1	1	10	100
$A_L(\%)$	96.4	98.6	99.1	99.84	99.85	99.85	99.4	99.8	99.4	95.3
$e_{mpe}(\%)$	2.6	1.0	0.7	0.09	0.08	0.08	0.4	0.1	0.4	3.2

对以上结果进行分析得知:(1)SVM 方法的预测精度明显优于神经网络方法。(2)农产品销售预测精度受天气变化情况的影响,当天气较晴朗且前后几天天气变化不大的情况下,预测精度较高,这基本符合客观实际。(3)采用 SVM 方法进行农产品销量预测时,参数的选择对预测精度的影响较大,需根据实际情况适当调节预测参数。

5 结束语

支持向量机通过某种事先选择的非线性映射将输入向量映射到一个高维特征空间,在这个空间中构造最优分类超平面。这种非线性变换是通过定义适当的核函数来实现的,所以预测中核函数的选取对预测精度有影响,这可以从试验的结果中看出。

支持向量机是从数据分类问题的研究中发展而来的,通常的神经网络方法进行数据分类最终获得的分类超平面将相当靠近训练集中的点,在绝大多数情况下,它并不是最优解。而支持向量机构造的是使分类间隔最大、错分样本最小的最优超平面。则支持向量机方法具有较高的拟合精度和较好的泛化性能,实际算例也验证了 SVM 的预测精度高于神经网络方法。

农产品未来需求除受历史需求的影响之外,还会随着天气变化、气候条件、节假日等因素的影响而发生实时的变化,在对农产品未来需求预测过程中,如果不考虑这些动态变化因素的影响,将会影响农产品的预测精度,因此,本文将这些影响因素纳入农产品需求预测中,并应用模糊理论进行模糊化处理,使预测过程尽量贴合于实际,提高了农产品需求预测的准确度。

参考文献:

[1] 孟万辰,郭文玲.河北省主要农产品生产与市场需求预测研究[J].中国农业资源与区划,2000,21(3):55-58.
 [2] 卜实,刘忠臣.专用大豆蛋白市场需求预测[J].大豆通报,2002,(1):26.
 [3] 陈宇科.商品销量的趋势分析及预测[J].渝西学院学报(自然科学版),2003,2(2):59-61.
 [4] 陈日进.销售预测中指数平滑法与时间序列分解法的

比较[J].统计与信息论坛,2004,19(4):40-43.
 [5] 曾晓三,张克平.我国白酒市场需求预测[J].酿酒,1994,(3):17-19.
 [6] 马建忠,邵则夏.核桃、板栗市场需求预测模型的研究[J].云南林业科技,2000,(2):59-62.
 [7] 刘豹,胡代平.神经网络在预测中的一些应用研究[J].系统工程学报.1999,14(4):338-344.
 [8] 白杨.人工神经网络在粮食销售额预测中的应用[J].农机化研究,2005,(3):207-208.
 [9] 邵良杉,付华,高树林.基于人工神经网络的投资预测[J].中国管理科学,1995,(4):13-19.
 [10] Cortes C, V. Vapnik. Support vector networks[J]. Machine Learning, 1995, 20(3):273-297.
 [11] Vapnik V. The Nature of Statistical Learning Theory [M]. Springer-Verlag, New York, 1995.
 [12] Smola A. and B. Scholkopf. On a Kernel-based Method for Pattern Recognition, Regression, Approximation and Operator Inversion [R]. GMD Technical Report No. 1064, 1997.
 [13] Smola A J, Scholkopf B. A tutorial on support vector regression[R]. Neuro COLT Tech. Rep. TR 1998-030, Royal Holloway College, London, U. K, 1998.
 [14] Steve Gunn. Support Vector Machines for Classification and Regression [R]. ISIS Technical Report, 14, May 1998, Image Speech and Intelligent Systems Group university of southampton.
 [15] K. R. Muller, A. Smola and B. Scholkopf et al Prediction time series with support vector machines[C]. in: Proceedings of International Conference on Artificial Neural Networks, 1997, 999.
 [16] Gestel T. V., Johan A. K. Suykens, Dirk - Emma Baestaens, A. Lambrechts, G. Lanckriet, B. Vandaele, B. D. Moor, J. Vandewalle. Financial time series prediction using least squares support vector machines within the evidence framework[J]. IEEE Transactions on Neural Networks, 2001, 12(4): 1-41.
 [17] 纪延光,徐启华,韩之俊.基于支持向量机的R & D项目过程质量度量[J].中国管理科学,2004,12(6):62-67.
 [18] Campbell C. Kernel methods: a survey of current techniques[J]. Neurocomputing, 2002, 48: 63-84.
 [19] 姜勇,卢毅.电力系统短期负荷预测的模糊神经网络

- 方法[J]. 电力情报, 2001, 8(4): 8- 10.
- [20] 姜飞, 龙子泉, 林峰. 模糊神经网络在电力短期负荷预测中的作用[J]. 自动化技术与应用, 2003, 22(8): 23- 26.
- [21] 刘秀玉, 刘峤. 一种基于模糊逻辑神经网络电力负荷预测方法[J]. 上海大学学报, 2001, 7(2): 37- 41.
- [22] Platt J. C. Fast training of support vector machines using sequential minimal optimization [C] . In B. Scholkopf, C. J. C. Burges, A. J. Smola, editors, *Advances in Kernel Methods – Support Vector Learning*, 185 – 208, MIT Press, 1998.
- [23] John C. Platt. Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines [R] . Technical Report MSR- TR- 98- 14, April 21, 1998.

A Support Vector Machine Method for Sales Forecast of Farm Products

DU Xiao- fang^{1,2}, ZHANG Jin- long²

(1. Wuhan University of Technology, Wuhan 430070, China;

2. School of Management, Huazhong University of Science & Technology, Wuhan 430074, China)

Abstract: A dynamic forecasting system of demands for farm products in consuming market is studied by means of applying the intelligent forecast method SVM (Support Vector Machine). In order to achieve higher forecast precision of farm product sale quantities, such factors as weather, climate conditions and demands on holidays etc., are introduced to the forecasting model, and the Fuzzy Theory is also applied to cope with the problem of fuzzification. Furthermore, an intelligent forecasting system is constructed, which is mainly based on SVM theory and combined with many other techniques. Using this system to dynamically forecast the demands for farm products, the practical application shows the precision of the forecasting method.

Key words: support vector machine; farm products; sales forecast; fuzzy theory; kernel