

# 基于数据包络分析和人工神经网络的变量施肥决策方法研究

马成林<sup>1</sup>, 吴才聪<sup>2</sup>, 张书慧<sup>1</sup>, 杨印生<sup>1</sup>, 李洪伟<sup>1</sup>, 韩云霞<sup>1</sup>

(1. 吉林大学生物与农业工程学院, 长春 130022; 2 北京大学遥感与地理信息系统研究所, 北京 100871)

**摘要:** 采用数据包络分析( DEA )方法评价玉米施肥单元的投入产出技术效率, 把非 DEA 有效的单元进行投影, 使之 DEA 有效, 所获得的投影数据供神经网络训练使用。建立 3 层 BP 神经网络模型, 以土壤养分和产量为输入, 以施肥量为输出, 并结合输入输出的价格因素扩展模型, 实现利润最大化决策。该模型既为充分使用所有试验数据引入了可行方法, 又弥补了传统施肥决策方法中非线性关系描述的不足。应用表明, 该模型可以揭示施肥单元的需肥特性和提供最佳施肥方案, 目标产量不超过 9750 kg/hm<sup>2</sup> 时, 预测结果较合理。

**关键词:** 精确农业; 变量施肥; 决策; 数据包络分析; 人工神经网络

**中图分类号:** S157.4<sup>+</sup>1; TP183

**文献标识码:** A

**文章编号:** 1002-6819(2004)02-0152-04

## 0 引言

变量施肥技术的实施主要受机具作业精度和施肥决策精度两方面因素的影响。如果施肥决策结果不能反映作物对肥料的真实需求, 那么在施肥机上所做的任何技术改进, 都意义不大。由此可见, 变量施肥决策方法是否合理至关重要<sup>[1,2]</sup>。

传统施肥决策方法中, 定量方法主要有养分平衡法和肥料效应函数法两种。养分平衡法待定系数较多, 而且不能反映养分间的交互作用, 难于推广。肥料效应函数法由几个一元二次方程描述, 使用简单, 但是由于未考虑土壤养分含量, 误差较大。由于产量和土壤养分、施肥量以及其它影响因素间呈高度的非线性, 可以较好地反映非线性的人工神经网络被应用于施肥决策。Scott Drummond<sup>[3]</sup>等成功地运用“7-10-1”BP 神经网络寻找作物产量与农田高程、pH 值、有机质、速效磷、速效钾、阳离子交换率和耕层厚度之间的非线性关系。国外此类研究比较广泛和深入, 所取得的效果也比较好<sup>[4-6]</sup>。在国内, 潘大丰等<sup>[7]</sup>使用了神经网络建造蔬菜施肥专家系统。

作者于 2002 年对德惠试验田进行了测土、施肥和测产, 经过处理, 获得 38 组有效数据(按施肥单元/网格存储)。这些数据用简单的线性和非线性回归进行拟合, 难以得到良好的效果。因此, 本文使用数据包络分析法(Data Envelopment Analysis, 简记 DEA)对所有网格投入产出的技术效率进行评价, 把非 DEA 有效的网格进行投影, 使其 DEA 有效, 以供神经网络充分利用所有试验数据。然后, 建立 BP 神经网络模型, 以土壤养分和目标产量为模型输入, 以施肥量为模型输出, 进行神经网络训练, 直至获得满意的施肥决策模型。在此基础上, 结

合投入产出的价格因素扩展模型, 实现利润最大化决策。

## 1 方法

### 1.1 数据包络分析法( DEA )

DEA 使用数学规划模型比较决策单元之间的相对效率, 对决策单元( Decision Making Unit, 简记 DMU )做出评价。通过对输入和输出数据综合分析, DEA 可以得出每个 DMU 综合效率的数量指标, 据此将各 DMU 定级排队, 确定有效的(即相对效率高的)DMU, 并指出 DMU 非有效的原因和程度。DEA 常用模型有 C<sup>2</sup>R 和 BCC 模型, 它们又分别有输入和输出两种模型。C<sup>2</sup>R 模型同时评价 DMU 的技术和规模有效性, BCC 模型用于评价 DMU 的技术有效性<sup>[8,9]</sup>。

图 1 为单输入单输出的生产函数  $y = f(x)$  的曲线。它表示生产处于理想状态时, 投入量为  $x$  时所能获得的最大产出量为  $y$ 。因此, 生产函数曲线上的点  $A(x_1, y_1)$ 、 $C(x_3, y_3)$  代表的 DMU 都处于“技术有效”的理想状态, 而点  $B(x_2, y_2)$  不在生产函数曲线上, 是非技术有效的,  $B'$  为  $B$  在减少投入的情况下在生产函数上的投影, 是技术有效的。

图 1 生产函数曲线

Fig 1 Curve of production function

收稿日期: 2003-03-06 修订日期: 2004-01-02

基金项目: 吉林省科委项目(20000201-3-1); 吉林省杰出青年科学研究计划资助项目

作者简介: 马成林(1935-), 男, 辽宁营口人, 教授, 博士生导师, 长春市吉林大学生物与农业工程学院, 130022

通讯作者: 吴才聪, 男, 博士后, 北京中关村 北京大学遥感与地理信息系统研究所, 100871。Email: wucc@pku.edu.cn

BCC 输出模型如下:

$$\begin{aligned} \max & Z \\ \text{s.t.} & \sum_{j=1}^n X_j \lambda_j + S^- = X_0 \end{aligned}$$

$$\begin{aligned} & \sum_{j=1}^n Y_j \lambda_j - S^+ = Z Y_0 \\ & \sum_{j=1}^n \lambda_j = 1 \\ & \lambda_j \geq 0, j = 1, 2, \dots, n \\ & S^- \geq 0, S^+ \geq 0 \end{aligned}$$

式中  $X_j, Y_j$ ——输入和输出;  $n$ ——DMU 数量;  $Z$ ——效率指数;  $S^-, S^+$ ——松弛因子;  $\lambda_j$ ——系数。

设正在评价的 DMU 是  $j_0$ 。当  $Z = 1$ , 且  $S^- = 0, S^+ = 0$  时, 称 DMU  $j_0$  为 BCC 输出模型下的 DEA 有效, 即 DMU  $j_0$  为“技术有效”; 若仅仅  $Z = 1$  时, 称 DMU  $j_0$  为 BCC 输出模型下的弱 DEA 有效。如果 DMU  $j_0$  非 DEA 有效, 则通过尽量减少投入来使 DMU  $j_0$  变得有效, 即计算其“投影”。

$$\begin{aligned} \hat{X}_{j_0} &= X_{j_0} - S^- = \sum_{j=1}^n X_j \lambda_j^0 \quad X_{j_0} \\ \hat{Y}_{j_0} &= Z^0 Y_{j_0} + S^+ = \sum_{j=1}^n Y_j \lambda_j^0 \quad Y_{j_0} \end{aligned}$$

$(\hat{X}_{j_0}, \hat{Y}_{j_0})$  作为一个新的 DMU, 相当于原来  $n$  个 DMU 来说, 一定是有效的, 它提供了将 DMU  $j_0$  转变为 DEA 有效而在输入与输出必须达到的目标。

### 1.2 人工神经网络

BP 神经网络是一种应用比较广泛的神经网络模型。数学已经证明, 只要隐含层具有足够多的神经元, 3 层 BP 神经网络(如图 2 所示, 输入层、隐含层和输出层各一层, 隐含层和输出层分别使用 tansig 函数和 purlin

纯线性函数)可以逼近任何函数。




图 2 典型的 3 层 BP 神经网络结构

Fig. 2 Structure of typical 3-layer BP artificial neural network

模型训练时易发生“过度吻合”, 致使模型的泛化能力不强<sup>[10, 11]</sup>。如果训练数据足够多(远远大于网络训练参数), 则无须担心过度吻合。自动正则化方法可以避免过度吻合, Matlab 提供的 trainbr 函数可实现此方法。

## 2 变量施肥决策方法

### 2.1 DEA 相对效率评价

每个施肥网格都具有相同的输入指标: 碱解氮(N)、速效磷(P)、速效钾(K)和施氮量(FN)、施磷量(FP)、施钾量(FK), 输出指标是产量(Yield)。各网格均在同一块试验田中, 其水分、光照、气候和病虫害情况基本一致。因此, 可使用 DEA 方法对所有网格进行施肥技术效率评价, 判定其有效性程度。评价结果(相对效率指数)用  $Z$  表示, 对于非 DEA 有效的 DMU 进行投影, 结果见表 1。表 1 中接近 50% 的网格为非 DEA 有效, 这说明部分输入存在浪费, 有必要调整其输入。

表 1 2002 年德惠试验田施肥数据 DEA 投影及效率指数

Table 1 The DEA projections and efficiencies of fertilizer data in Dehui experimental plot in 2002

DMU	N P K			FN FP FK			Yield	Z	DMU	N P K			FN FP FK			Yield	Z
	/mg · kg <sup>-1</sup>			/kg · hm <sup>-2</sup>						/mg · kg <sup>-1</sup>			/kg · hm <sup>-2</sup>				
1	101.50	9.12	199	160	23	0	7713	1	20	110.54	15.30	193	171	21	37	6440	1.51
2	92.79	11.56	186	160	23	0	7760	1	21	99.32	15.49	165	171	21	37	9698	1
3	109.60	10.10	191	160	23	0	8361	1	22	99.64	14.70	183	171	21	37	7249	1.30
4	107.42	14.80	193	158	0	0	8038	1	23	153.81	17.06	205	176	23	40	9770	1
5	99.02	15.78	196	158	0	0	7078	1	24	130.77	11.08	188	176	23	40	8707	1.10
6	107.73	17.26	203	158	0	0	9192	1	25	121.12	8.43	193	176	23	40	6957	1.29
7	104.30	20.98	202	158	0	0	9007	1	26	111.47	16.76	198	176	23	40	6689	1.47
8	199.27	15.98	199	180	24	43	10508	1	27	115.83	8.73	199	141	23	40	7857	1.08
9	146.96	16.38	210	179	24	42	8741	1.08	28	128.28	10.59	204	141	23	40	8609	1.09
10	146.96	21.56	239	168	20	35	7502	1.32	29	113.02	11.57	195	141	23	40	7489	1
11	145.72	13.14	188	189	28	48	9070	1.10	30	112.72	22.55	192	141	23	40	6995	1.30
12	118.94	7.56	192	155	28	49	7383	1.12	31	199.27	15.98	199	165	62	110	9170	1.18
13	127.66	7.16	181	149	26	45	9304	1	32	146.96	16.38	210	165	62	110	11229	1
14	129.53	6.56	173	152	27	47	8510	1	33	146.96	21.56	239	165	62	110	9167	1.22
15	141.05	9.61	176	137	21	37	6985	1.27	34	145.72	13.14	188	165	62	110	9655	1.05
16	94.34	12.16	187	176	23	40	6332	1.28	35	153.81	17.06	205	0	0	0	7122	1
17	94.96	14.12	205	176	23	40	6419	1.31	36	130.77	11.08	188	0	0	0	7080	1
18	99.01	14.42	183	176	23	40	8464	1	37	121.12	8.43	193	0	0	0	5210	1
19	98.71	17.16	199	176	23	40	7696	1.24	38	111.47	16.76	198	0	0	0	5133	1

## 2.2 建立施肥决策BP网络模型

### 2.2.1 数据处理

使用  $\text{Premnm}$  函数把训练数据和预测数据归一化处理到  $[-1, 1]$  区间, 使用  $\text{Prepca}$  函数对训练数据输入指标进行主成分分析, 并把全部数据分解成两组: 训练数据 (33 组) 和测试数据 (5 组)。

### 2.2.2 网络结构

采用图 2 所示 BP 网络结构。输入层和输出层神经元分别为 N、P、K、Yield 和 FN、FP、FK。隐含层神经元数量通过尝试确定, 即从 3~14 个之间依次训练, 挑选合理的结果。由于数据比较少, 为避免过度吻合, 训练函数选用  $\text{trainbr}$ , 学习步长为 0.05, 训练目标为 0.001。

### 2.2.3 网络训练

经过反复训练, 发现隐含层超过 8 个神经元时发生过度吻合, 4 个神经元时对各组测试数据误差较小, 而且比较稳定。因此, 隐含层确定用 4 个神经元<sup>[12, 13]</sup>。重新合并训练数据和测试数据, 即把全部数据用于训练, 以便充分利用所有数据。经过 141 次训练后, FN、FP、FK 的训练平均绝对误差为 8.08、1.84 和 4.13, 相关系数分别为 0.981、0.983 和 0.978, 网络训练误差平方和为 1.16, 因此获得有较好训练精度的变量施肥决策 BP 神经网络模型。

### 2.3 模型扩展

农民关心的是效益, 而不仅仅是产量, 有必要把模型和投入产出的价格因素结合起来, 实现利润最大化施肥决策。玉米种植的主要投入物是: 种子、水、农药、人工、柴油和化肥等。除化肥外, 其余各项均可视为常数。磷肥和钾肥作为底肥 (复合肥) 一次性施入, 氮肥由追肥 (尿素) 补足。由于变量施肥机只能同比例地调整 N、P、K 的投入, 因此, 施底肥时只好同时保证钾和磷的施用量。

设复合肥、尿素和玉米价格分别为  $p_1$ 、 $p_2$  和  $p_3$  (元/kg), 复合肥 N、P、K 含量分别为  $\alpha$ 、 $\beta$ 、 $\gamma$ , 氮、磷、钾需求量分别为 FN、FP 和 FK ( $\text{kg}/\text{hm}^2$ ), 尿素含氮 46.3%。则第  $i$  个施肥网格投入产出为:

$$\text{底肥施用量 } DF_i = \text{最大值}(FP_i/\beta, FK_i/\gamma);$$

$$\text{底肥成本 } DFC_i = DF_i \times p_1;$$

追肥施用量  $ZF_i = (FN_i - DF_i \times \alpha) / 46.3\%$ , 如果  $ZF_i < 0$ , 则  $ZF_i = 0$ ;

$$\text{追肥成本 } ZFC_i = ZF_i \times p_2;$$

$$\text{化肥总成本 } FC_i = DFC_i + ZFC_i;$$

$$\text{玉米销售收入 } I_i = \text{Yield}_i \times p_3;$$

$$\text{玉米种植利润 } B_i = I_i - FC_i - OC_i.$$

$OC_i$  为除化肥外的各项投入品 (未计税费) 价值总和, 2002 年德惠试验田这项投入约合 1280 元/ $\text{hm}^2$ 。给定上述参数, 可确定施肥网格的合理方案。

## 3 模型应用实例

利用变量施肥决策模型对 2003 年榆树试验田进行施肥决策<sup>[14, 15]</sup>。复合肥、尿素和玉米的价格分别为 1.6 元/kg、1.5 元/kg 和 0.85 元/kg, 复合肥 N、P、K 含量

分别为 15%、5.7% 和 9.8%。目标产量在 7500~10875  $\text{kg}/\text{hm}^2$  之间每隔 375  $\text{kg}/\text{hm}^2$  取一个值用于模型决策, 以目标产量为横轴, 输出为纵轴, 绘制图 3。

从图 3a 和 3b 可以看出, 目标产量小于 9750  $\text{kg}/\text{hm}^2$  时, 需肥特性曲线 (目标产量与施肥量关系曲线) 与肥料效应函数法的曲线相似, 可以解释目标产量增长对化肥需求变化情况。当目标产量大于 9750  $\text{kg}/\text{hm}^2$  时, 氮肥的变化趋势不理想, 可能是由于训练数据中氮肥施用量不超过 180  $\text{kg}/\text{hm}^2$  造成的。以网格 32 和 40 为例。网格 40 比网格 32 的土壤养分值低, 前者对磷肥和钾肥需求的增长要快于后者, 说明不同网格由于基础肥力不一样, 其需肥特性不一样。而同一个网格对 NPK 的需求也不一样, 图 3a 中, 网格 32 的目标产量小于 9000  $\text{kg}/\text{hm}^2$  时, 氮肥的增长比较快, 磷钾肥基本保持不变, 目标产量大于 9000  $\text{kg}/\text{hm}^2$  时, 氮肥增长减缓, 磷钾肥的增长较快。

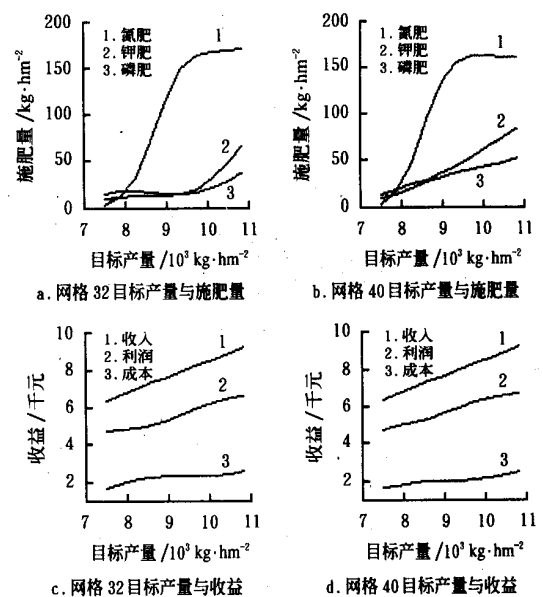


图 3 目标产量、施肥量与收益关系

Fig. 3 Relationships between aim yield, fertilizer application rate and profit

图 3c 和 3d 反映了目标产量与收益的关系。随着目标产量的增长, 利润保持增长。因此, 对于网格 32, 增加目标产量, 可以获得更多的利润。但是, 由于榆树试验田受水供应的制约, 产量一般不高于 9750  $\text{kg}/\text{hm}^2$ 。如果不考虑其它投入的制约, 网格 32 的最佳施肥方案为: 氮、磷、钾分别施用 163  $\text{kg}/\text{hm}^2$ 、16  $\text{kg}/\text{hm}^2$  和 20  $\text{kg}/\text{hm}^2$ , 预计生产成本和利润分别为 2122 元/ $\text{hm}^2$  和 6166 元/ $\text{hm}^2$ 。同理, 网格 40 最佳施肥方案宜为: 氮、磷和钾分别施用 161  $\text{kg}/\text{hm}^2$ 、40  $\text{kg}/\text{hm}^2$  和 54  $\text{kg}/\text{hm}^2$ , 预计生产成本和利润分别为 2586 元/ $\text{hm}^2$  和 5702 元/ $\text{hm}^2$ 。可见, 土壤基础肥力不同造成的施肥方案和预期投入及利润的差异是明显的, 每个网格都有其自身的最佳施肥方案。

## 4 结论

本文基于数据包络分析和人工神经网络, 建立了

BP神经网络施肥决策模型, 既为充分使用所有试验数据引入了可行方法, 又弥补了传统施肥决策方法中非线性关系描述的不足。应用表明: 目标产量不超过 9750 kg/hm<sup>2</sup> 时, 模型预测结果较为合理, 可以反映玉米的需肥特性。

要提高模型的泛化能力, 需要训练更多、更有代表性的数据。而且, 施肥效果影响因素众多, 除土壤养分和施肥量外, 水分、光照、品种、病虫害造成的影响也不可忽视, 这尚需进一步的研究。

#### [参 考 文 献]

- [1] 张书慧, 马成林, 吴才聪, 等. 一种精确农业自动变量施肥技术及其实施[J]. 农业工程学报, 2003, 19(1): 129~ 131.
- [2] 张书慧, 马成林, 于春玲. 应用于精确农业变量施肥地理信息系统的开发研究[J]. 农业工程学报, 2002, 18(2): 153-155.
- [3] Drummond S T, Joshi A, Sudduth K A. Application of neural networks: precision farming[A]. Anchorage, AK: Proc IEEE World Congress on Computational Intelligence [C], May 4- 9, 1998, 211- 215.
- [4] Jac J V arco, Marvin L Salin, Susan M Bridges. Remote sensing applications in the optimization of cotton nitrogen fertilization [R]. 1999- 2000 RSTC Funded Final Research Report.
- [5] Shearer S A, Burks T F, Thomason J A, et al. Yield prediction using a neural network classifier trained using soil landscape features and soil fertility data[A]. ASA E, 1999, Paper No. 99- 3042 Toronto, Canada: Annual International Meeting[C], July 18- 21, 1999.
- [6] Broner, Com stock. Combining expert systems and neural networks for learning site-specific conditions [J]. Computers and Electronics in Agriculture, 1997, 19(1): 37- 53.
- [7] 潘大丰, 程季珍, 李群, 等. 蔬菜施肥专家系统[J]. 华北农学报, 2000, 15(3): 118- 121.
- [8] 杨印生. 经济系统定量分析方法[M]. 长春: 吉林科学技术出版社, 2001.
- [9] 隗志才, 等. DEA方法与运输企业技术规模的有效性[J]. 公路交通科技, 1994, 11(4): 44- 50.
- [10] 李光金, 等. 评价相对效率的投入——产出型DEA[J]. 管理科学学报, 2001, 4(2): 58- 62.
- [11] 耿昌松, 等. 应用Matlab建立焊接参数人工神经网络模型的方法[J]. 焊接, 2001, (5): 14- 16.
- [12] Nils J Nilsson. Artificial intelligence a new synthesis [M]. Beijing: China Machine Press, 1999.
- [13] 屈忠义, 陈亚新, 史海滨, 等. 内蒙古河套灌区节水灌溉工程实施后地下水变化的BP模型预测[J]. 农业工程学报, 2003, 19(1): 59- 62.
- [14] 吴才聪, 张书慧, 马成林, 等. 利用MapBasic划分精确农业田块网络方法的研究[J]. 农业工程学报, 2002, 18(2): 156- 159.
- [15] 吴才聪, 马成林, 张书慧, 等. 精确农业倾斜网格划分及其应用[J]. 农业工程学报, 2003, 19(1): 137- 141.

## Decision making method for variable-rate fertilization based on data envelopment analysis and artificial neural network

Ma Chenglin<sup>1</sup>, Wu Caicong<sup>2</sup>, Zhang Shuhui<sup>1</sup>, Yang Yinsheng<sup>1</sup>, Li Hongwei<sup>1</sup>, Han Yunxia<sup>1</sup>

(1. School of Bio-agricultural Engineering, Jilin University, Changchun 130022, China;

2. Institute of Remote Sensing and GIS, Peking University, Beijing 100871, China)

**Abstract:** Data Envelopment Analysis (DEA) method was used to evaluate technical efficiency of input and output of the corn fertilizing unit, and to turn the inefficient unit into effective unit through projections. Then all the data were well prepared for the Artificial Neural Network (ANN) by this way. In Matlab program, BP ANN model with three layers was developed with soil nutrients and yield as inputs, and with fertilizer application rate of nitrogen, phosphorus and potassium as outputs. Automated regularization function tainbr was chosen to train the network, and the decision making model of variable-rate fertilization could be obtained by this way. The model can also consider the price factors as input and output to enlarge its function to make decision to achieve the maximum profits. In other words, the model can not only introduce an effective method to utilize all the experimental data, but also can solve the non-linear problems that cannot be solved by traditional decision method. The application shows that the model can describe the fertilizer demand property and provide optimum scheme of fertilization for every fertilizing unit. When aim yield is not higher than 9750 kg/hm<sup>2</sup>, the estimation result is quite reasonable.

**Key words:** precision agriculture; variable-rate fertilization; decision making; data envelopment analysis; artificial neural network