

# 基于 NPCA-SOFM 算法的电力物资细分模型<sup>①</sup>

牛庆松<sup>1</sup>, 蒋雷雷<sup>1</sup>, 刁柏青<sup>2</sup>

<sup>1</sup>(国网临沂供电公司, 临沂 276003)

<sup>2</sup>(国网山东省电力公司, 济南 250001)

**摘要:** 为了有效提高电力物资细分科学性以及需求预测合理性, 文章以物资需求特性为突破口, 构建了基于 NPCA-SOFM 算法的电力物资细分模型. 首先, 为消除指标标准化造成的指标变异和信息丢失影响, 采用非线性主成份分析法 (NPCA) 进行降维处理; 然后, 运用 SOFM 神经网络算法对降维后的主成份进行聚类分析; 最后, 通过算例分析验证文中方法的有效性, 结果表明相较于 PCA-SOFM 和单独采用 SOFM 算法, NPCA-SOFM 神经网络算法聚类性能更具优势, 且降维效果更明显, 可为电力物资集约化管理和企业运营决策提供参考意义.

**关键词:** 物资细分; 非线性主成份分析; 自组织映射神经网络; 智能电网

引用格式: 牛庆松, 蒋雷雷, 刁柏青. 基于 NPCA-SOFM 算法的电力物资细分模型. 计算机系统应用, 2017, 26(10): 172-177. <http://www.c-s-a.org.cn/1003-3254/6016.html>

## Power Material Subdivision Model Based on NPCA-SOFM Algorithm

NIU Qing-Song<sup>1</sup>, JIANG Lei-Lei<sup>1</sup>, DIAO Bai-Qing<sup>2</sup>

<sup>1</sup>(State Grid Linyi Power Supply Company, Linyi 276003, China)

<sup>2</sup>(State Grid Shandong Electric Power Company, Jinan 250001, China)

**Abstract:** In order to improve the scientificity of power material subdivision and the rationality of demand forecasting, this paper constructs the power material subdivision model based on NPCA-SOFM algorithm with the material demand characteristic as the breakthrough point. Firstly, the non-linear principal component analysis (NPCA) is used to reduce the dimensionality of the index and the loss of information caused by the standardization of indicators. Afterwards, we use the SOFM neural network algorithm to cluster the principal components after dimension reduction. Finally, the validity of the method is verified with an example. The results show that the clustering performance of NPCA-SOFM neural network algorithm is superior to PCA-SOFM and SOFM algorithm alone, and the dimension reduction effect is more obvious, which can provide reference value for intensive management of electric material and enterprise operation decision.

**Key words:** material subdivision; non-linear principal component analysis; self organization feature map; smart grid

随着坚强智能电网和三集五大战略的深入推行, 电网企业正在全网范围内积极开展统一物资管理体系<sup>[1]</sup>、物资集约化管理及物资合理库存控制等工作, 努力实现电力企业集约高效管理和资源优化配置, 其中电力物资细分是推进物资集约化管理进程中的重要问题<sup>[2]</sup>. 由于电力物资具有品种繁多、规格多样、数量巨大、用途广泛等特点, 造成集约化管理难度加大, 进而影响

物资需求预测和物资库存管理, 严重影响了电网物资供应链管理效率. 另外, 电力物资细分的合理性直接影响物资需求预测的准确性, 进而影响物资集约化管理效率, 并且传统的物资分类方法不能兼顾到其预测问题<sup>[3]</sup>. 现有的理论研究比较侧重于物资分类方法的改进以及库存控制策略, 但是结合需求特性进行物资细分的研究还比较少, 尽管电网企业已经对电力物资进行

① 基金项目: 国家自然科学基金 (71071089); 国家电网公司科技项目 (520607160003)

收稿时间: 2017-01-12; 采用时间: 2017-02-23

了大中小类的划分,其分类的依据是物资的性能参数和用途,但是尚未完善面向物资需求特性和库存管理的物资分类方法.因此,需要构建一套基于需求特性的、完备的及高效的电力物资细分模型方案.

电力物资细分就是基于特定需求对电力物资按属性规律进行分类的过程,进而提高企业物资管理效率和经济效益.目前国内外关于电力物资细分已经进行了较多研究工作<sup>[4-7]</sup>,文献[4]探讨了传统ABC分类法在针对需求量较少且单价较高的慢速流动物资时分配不合理缺点,以关键设备为出发点,构建了AHP和蒙特卡洛模拟两阶段法对不同物资进行ABC分类,提高了物资分类的操作性;文献[5]选取物资单价、订货成本、需求量和提前期作为输入属性,构建了神经网络模型对物资进行聚类分析,并将物资按照重要性划分为高中低三类;文献[6]高新华针对智能电网综合评价问题,提出了一种将主成份分析和聚类分析相结合的综合评价方法,将众多评价指标按数据的相关性转换成较高层次的综合指标,有效的避免了人工赋权的主观性干扰,降低了问题的复杂度;文献[7]洪芳华针对物资管理存在标准化程度低和库存成本高等问题,提出了一种基于需求特性分析的物资分类方法,并且对不同类别物资设计各个子类的库存管理策略矩阵,该方法对于物资种类较多时分类效率比较低.

鉴于以上研究现状,本文以物资需求特性为突破口,基于国网某省电力公司物资出入库等数据,构建了基于NPCA-SOFM神经网络算法的电力物资细分模型,采用非线性主成份分析法消除量纲及指标变异造成的信息丢失影响,将多指标转化为少数综合指标,然后,采用SOFM神经网络算法对电力物资进行细分,该算法能够自动识别样本信息并自组织性的完成聚类,受外界干扰性较小,针对多属性大样本情况性能更具优势,最后,通过算例应用,验证了本文所提方法的有效性.

## 1 电力物资细分指标体系粗选

物资细分是推进电力物资集约化管理和提高电力生产的关键环节,由于电力行业物资具有种类繁多、规格多样、覆盖面广和价格差异大等特点,且当前的物资分类方法缺乏统一的标准,现有的物资分类方法有基于物资属性划分、基于财务口径划分、按照用途划分、按照采购方式划分、按照供应复杂度划分等等,导致电力物资细分研究不能直接采用传统的RFM模

型(消费间隔R、消费频率F、消费金额M),本文在此基础上,以电力物资需求特性为突破口,通过专家调研法和头脑风暴法粗选出了影响电力物资需求量的8个细分指标,相应的指标体系见表1.

表1 电力物资细分粗选指标

编号	指标名称	编号	指标名称
1	物资金额(jezb)	5	领用次数(lycs)
2	缺货成本(qhcb)	6	领用数量(lysl)
3	订货周期(dhzq)	7	应急采购比(yjcgb)
4	抢修占比(qxzb)	8	抢修金额(qxje)

## 2 基于NPCA-SOFM算法的电力物资细分模型构建

为了更加高效的提高电力物资库存合理性和物资管理效率,不断提升电力物资分类的科学性和电力物资需求预测精度,本文构建了基于NPCA-SOFM的电力物资细分模型<sup>[8]</sup>,在物资细分指标粗选的基础上,首先,为了弥补主成份分析法降维效果不理想的不足,采用非线性主成份分析法NPCA对指标进行降维处理,将原始指标转换为少数综合指标,且尽可能多保留原始数据的特征信息;然后,构建SOFM神经网络模型对电力物资进行细分,并将综合指标作为神经网络的输入,其自组织性和竞争性使得算法学习过程完全依据样本本身特征,降低外界环境的影响,最大限度的提高了算法性能<sup>[9]</sup>.模型的总体思路如图1.

### 2.1 基于NPCA的电力物资细分指标确定

为了从多维度甄选物资细分指标,所选取的评价指标往往比较多,从而导致物资细分变得非常复杂,传统的主成份分析法PCA通过降维思想将多指标转化为少数综合指标,降低了问题的求解难度,但是PCA在降维中存在许多不足之处:一是在为了消除量纲影响而进行标准化时,会造成指标变异程度上的差异以及信息丢失,从而使得特征值提取性下降;二是由于主成份实际上是一种线性降维技术,所得的主成份是原始指标的线性组合,不能反映各指标之间以及主成份与各指标间的非线性关系.为了有效弥补主成份分析的不足,提高算法的有效性,本文采用非线性主成份分析法(non-linear principal component analysis, NPCA)确定物资细分指标,在前文构建的物资评价指标体系的基础上,采用非线性主成份法对原始指标进行降维处理,不仅可消除量纲变异的影响,而且可提高主成份提取的有效性.其主要分析步骤如下:

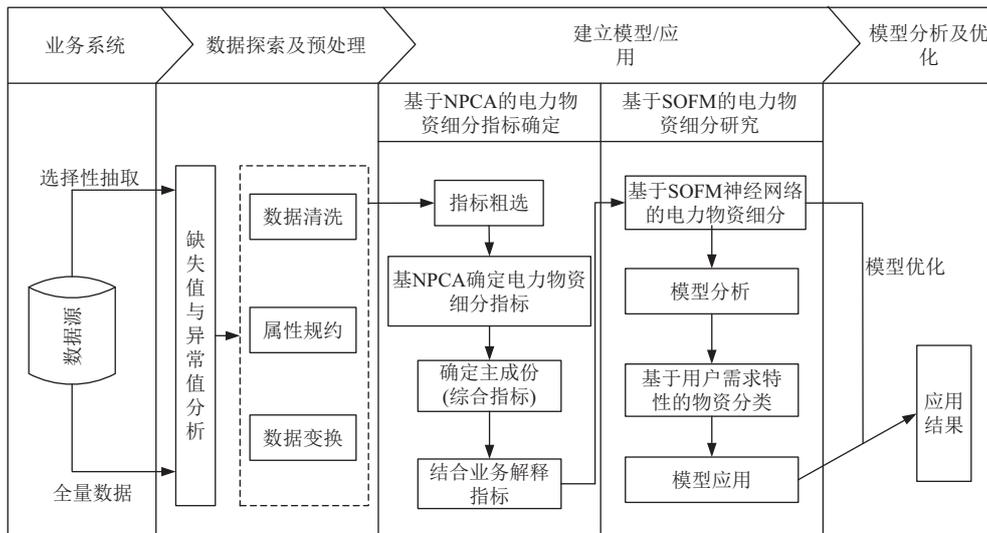


图1 物资细分模型总体思路

(1) 设有  $n$  个样本, 每个样本有  $p$  项指标, 得到原始数据,  $X = (x_{ij})_{n \times p}$  对原始数据进行均值化处理:

$$y_{ij} = \frac{x_{ij}}{\bar{x}_j} \quad (i = 1, 2, \dots, n; j = 1, 2, \dots, p) \quad (1)$$

其中,  $\bar{x}_j = (1/n) * \sum_{k=1}^n X_{kj}$ , 得到均值化数据  $Y = (y_{ij})_{n \times p}$ .

(2) 对均值化数据做中心化对数变换:

$$z_{ij} = \lg y_{ij} - \frac{1}{p} \sum_{t=1}^p \lg y_{it} \quad (2)$$

(3) 计算对数中心化数据的协方差矩阵:

$$s_{ij} = \frac{1}{n} \sum_{t=1}^n (z_{ti} - \bar{z}_i)(z_{tj} - \bar{z}_j) \quad (3)$$

$$\bar{z}_i = \frac{1}{n} \sum_{k=1}^n z_{ki}, \quad \bar{z}_j = \frac{1}{n} \sum_{k=1}^n z_{kj} \quad (4)$$

(4) 计算协方差矩阵的特征值  $\lambda_i$  和特征向量  $l_i$ .  $S$  的  $p$  个特征值记为:  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ , 标准化特征向量为  $\alpha_{ij} = (\alpha_{1j}, \alpha_{2j}, \dots, \alpha_{pj})$ , 则第  $m$  个样本指标的第  $i$  个主成份为:

$$F_{ki} = \sum_{j=1}^p \alpha_{ij} \lg y_{kj} \quad (5)$$

其中,  $i = 1, 2, \dots, p; j = 1, 2, \dots, p; k = 1, 2, \dots, n$ , 很显然,  $F_{ki}$  是  $y_{ki}$  的非线性组合.

(5) 计算主成份贡献率及累计贡献率. 一般选取累计贡献率大于 80% 的特征值对应的主成份  $m$ , 这  $m$  个主成份就综合体现了所有指标的大部分信息.

主成份贡献率:

$$\lambda_i / \sum_{k=1}^n \lambda_k \quad (6)$$

主成份累计贡献率:

$$\sum_{k=1}^i \lambda_k / \sum_{k=1}^n \lambda_k \quad (7)$$

(6) 计算各主成份得分  $Z_{ij}$ , 将其作为电力物资细分的综合指标.

$$Z_{ij} = V_{ij} * l_i \quad (8)$$

## 2.2 基于 SOFM 神经网络算法的电力物资细分模型

自组织映射神经网络 (Self organization feature map, SOFM) 由芬兰赫尔辛基大学教授 Kohonen 于 1981 年提出. 由于基于需求特性的物资细分指标复杂多变和数量较多, 且各指标之间往往又由许多隐含层次因素交互作用影响, 因此, 本文构建了 SOFM 神经网络算法对物资进行聚类分析, 将前文得到的少数综合指标作为神经网络输入, 通过算法的自组织性和竞争学习过程自动完成聚类过程, 聚类过程完全依据样本本身的属性特征, 受外界干扰较小, 相比于传统的聚类算法, 其具有更优秀的聚类性能<sup>[10]</sup>. 模型的主要思路如下:

(1) 构建包括输入层和竞争层的神经网络, 网络拓扑结构为矩形网格结构, 竞争层包括  $n \times m$  个神经元.

(2) 网络初始化及邻域半径的确定. 将神经网络的输入节点和竞争层神经元之间实现全连接, 有  $N$  个相

应的权值向量,对所有的权值向量 $\{W_{ij}\}$ 赋予 $[0, 1]$ 区间内的随机数,并且对所有的权值向量进行归一化处理,确定初始邻域半径 $N_g(0)$ ,学习率 $\eta(0)(0 < \eta(0) < 1)$ ,一般情况下,邻域半径应该覆盖所有邻域距离的 $2/3$ .权值向量应满足:

$$\sum_{i=1}^n W_{ij} = 1 \quad (9)$$

(3) 样本输入.在学习过程中,当样本进行输入时,竞争层神经元进行响应,从而调整权值向量优化神经网络.样本输入就是从训练集中随机的抽取一个输入模式并且对其进行归一化处理进行输入,得到 $X_k = (X_1, X_2, \dots, X_n)$ , $n$ 为输入神经元数目.

$$\bar{X}_k = \frac{X}{|X|} = \left[ x_1 / \sqrt{\sum_{j=1}^n X_j^2}, \dots, x_n / \sqrt{\sum_{j=1}^n X_j^2} \right]^T \quad (10)$$

(4) 寻找获胜神经元.样本输入后,竞争层神经元受到刺激调整最终会选择权值向量最相似的向量对象的神经元成为获胜神经元,两个模式向量的相似程度通常用二者的欧式距离来进行判断,计算公式为:

$$d_j = \sum_{i=1}^n (X_i^k - W_{ij})^2 \quad (11)$$

选择距离最小时对应的节点 $N_j^*$ 为竞争获胜神经元:

$$d_{j^*} = \min_{j \in \{1, 2, \dots, m\}} \{d_j\} \quad (12)$$

(5) 定义优胜邻域.优胜邻域是以获胜神经元为中心,设定一定距离的半径的一个区域,在网络的学习过程中,随着迭代次数的增加,权值向量不断自组织和调整,优胜邻域不断缩小为零,模式趋于稳定. $N_j^*$ 表示获胜神经元的邻域,其应满足:

$$N_{j^*} = \{m, d_j < d\} \quad (13)$$

(6) 权值调整.当样本输入后,获胜神经元及其优胜邻域范围内的神经元会以自组织形式不断调整权值向量,从而使得权值向量更加接近输入样本的模式向量,经过反复的训练之后,各个神经元就会形成固有的特征,从而达到对样本进行聚类的效果<sup>[1]</sup>.权值向量调整方式如下:

$$W_{ij}(k+1) = W_{ij}(k) + \eta[x_i(k) - \widehat{W}_{ij}(k)]; \quad (14)$$

$$0 \leq \eta \leq 1$$

(7) 检查结束.随着时间的推移以及迭代次数的增

加,学习率会不断的减小,使得输入样本自组织性的被聚类,判断结束的标准为学习率逐渐减小为定值或者神经元平均领域距离趋于定值.

### 2.3 模型评估

轮廓系数(Silhouette coefficient)通过考察类之间的分离情况和紧凑情况来评估聚类效果.对于 $n$ 个对象的数据集 $D$ ,假设 $D$ 被划分成 $k$ 个簇 $C_1, C_2, \dots, C_k$ .对于每个对象 $o \in D$ ,计算 $o$ 与其所属类其他对象的平均距离 $a(o)$ ,以及 $o$ 与其他类的最小平均距离 $b(o)$ .假设 $o \in C_i (1 \leq i \leq k)$ ,则:

$$a(o) = \frac{\sum_{o' \in C_i, o' \neq o} \text{dist}(o, o')}{|C_i| - 1} \quad (15)$$

而

$$b(o) = \min_{C_j: 1 \leq j \leq k, j \neq i} \left\{ \frac{\sum_{o' \in C_j} \text{dist}(o, o')}{|C_j|} \right\} \quad (16)$$

对象 $o$ 的轮廓系数为:

$$s(o) = \frac{b(o) - a(o)}{\max\{a(o), b(o)\}} \quad (17)$$

$a(o)$ 的值反映 $o$ 所属类的紧凑性,该值越小越紧凑, $b(o)$ 的值反映 $o$ 与其它类的分离程度, $b(o)$ 的值越大, $o$ 与其它类越分离.因此,当 $o$ 的轮廓系数接近1时,则表示 $o$ 所属的类是紧凑的,并且远离其它类,模型聚类效果越明显.

## 3 算例分析

为了验证模型的有效性和适用性,本文采集了某公司2013年至2016年300多万条物资出入库数据进行分析研究.目标数据集包括1571个物资小类,并由选取的八个关键指标为评价指标,采用RStudio软件进行数据分析,对建立的电力物资细分模型进行验证分析.

### 3.1 非线性主成份分析指标确定

为了更加合理的消除各指标的量纲差异,在保证系统信息量的前提下,采用非线性主成份对变量进行降维处理,为物资细分指标的确定提供依据.选取了1571种物资数据作为研究样本,物资指标体系选取8个关键指标,并对数据进行对数中心化、标准化预处理,结合R软件进行非线性主成份分析,主成份的选择依据主成份累计方差贡献率大于80%,通过计算可知,

各主成份方差贡献率见表2.

表2 各主成份方差贡献度

主成份	标准差	方差占比	累积值
Comp.1	1.6958	0.3595	0.3595
Comp.2	1.3710	0.2350	0.5944
Comp.3	0.9797	0.1200	0.7144
Comp.4	0.9007	0.1014	0.8158
Comp.5	0.8350	0.0872	0.9030
Comp.6	0.6778	0.0574	0.9604
Comp.7	0.4654	0.0271	0.9875
Comp.8	0.3167	0.0125	1.0000

由上表可以看出,主成份一、主成份二、主成份三和主成份四的累计方差贡献率达到81.6%(大于80%),故只需选取主成份一、主成份二、主成份三和主成份四,即可代表原来的8个指标的大部分信息,各

主成份因子载荷矩阵见表3.

由表3各主成份因子载荷矩阵可以看出,第一主成份在物资金额、缺货成本和领用次数三个指标上载荷较高,则认为第一主成份代表了物资的重要性程度;第二主成份在抢修金额和抢修数量占比两个指标上载荷较高,则认为第二主成份代表了物资的紧急性;第三主成份在缺货成本和应急采购占比两个指标上载荷较高,则认为第三主成份代表了物资的稀缺性;第四主成份在缺货成本和领用数量两个指标上载荷较高,则认为第四主成份代表了流通性.通过因子载荷矩阵可求得各物资在四个主成份的综合得分,并将其作为下一步神经网络模型的输入,即输入变量为:重要性、紧急性、稀缺性和流通性.

表3 各主成份因子载荷矩阵

	Comp.1	Comp.2	Comp.3	Comp.4	Comp.5	Comp.6	Comp.7	Comp.8
jezb_new	0.43	-0.35	0.00	0.00	-0.15	0.53	0.61	0.00
qhcb_new	0.12	0.33	-0.62	0.63	-0.28	0.12	0.00	0.00
dhzq_new	0.24	-0.41	0.34	0.43	-0.41	-0.55	0.00	0.00
qxzb_new	0.20	0.55	0.41	0.21	0.29	-0.17	0.36	0.45
lycs_new	0.53	-0.13	0.00	-0.12	0.00	0.24	-0.60	0.51
lysl_new	0.28	0.32	-0.19	-0.60	-0.56	-0.30	0.16	0.00
yjcg_new	0.34	-0.24	-0.48	0.00	0.56	-0.46	0.22	0.00
qxje_new	0.47	0.35	0.24	0.00	0.12	0.00	-0.25	-0.72

### 3.2 SOFM 神经网络学习及训练过程

基于非线性主成份分析法选择的4个主成份,采用SOFM神经网络算法对电力物资进行细分,通过调整参数及结果分析,将SOFM神经网络参数设置为:竞争层为2\*2的二维空间平面,为矩形网格结构,学习率线性变动区间为[0.05, 0.01],邻域半径为0.5,最大迭代次数为100次.此时,模型的聚类结果见表4.

表4 电力物资聚类结果

聚类类别	聚类中心				数量	占比(%)
	重要性	紧急性	稀缺性	流通性		
物资类1	-1.406	-0.715	-0.662	0.253	493	31.4
物资类2	-0.976	-2.498	2.111	-1.692	111	7.1
物资类3	3.264	-0.929	-1.039	-0.339	158	10.1
物资类4	0.366	0.932	0.369	0.147	809	51.5

平均轮廓系数:  $s = \frac{1}{n} \sum_{o=1}^n s(o) = 0.87$ .

由表4可知,1571种电力物资依据重要性、紧急性、稀缺性和流通性四个属性,被分为了四类,物资类1包含493中小类物资,物资类2包含111种小类物资,物资类3包含158种小类物资,物资类4包含

809种小类物资;另由平均轮廓系数为0.87可知,模型的聚类效果良好.

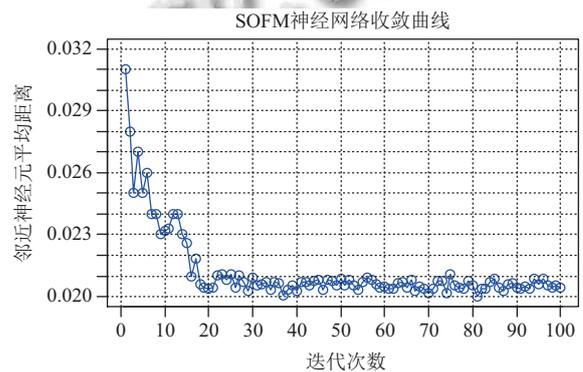


图2 SOFM神经网络收敛曲线

由图2可知,在自组织映射神经网络学习过程中,竞争层各神经元间的平均距离随着迭代次数的增加不断减小,并逐渐收敛为一个定值,当迭代次数达到第四十代左右的时候,竞争层神经元间平均距离收敛为0.0205,此时,模型趋于稳定状态.

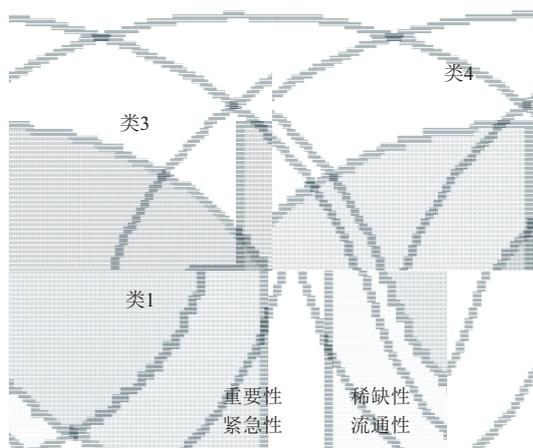


图3 物资特征分布图

图3反映了各神经元在各属性上的重要程度,可以清晰的看出:

第一类物资属于流通性比较强的物资,需求频次和需求量都比较大;第二类物资属于比较稀缺的物资,缺货成本比较高;第三类物资侧重于重要性和流通性,这类物资价值比较大、需求频次较高;第四类物资属于紧急程度高且流通性比较快的物资。

在实际应用中,企业可以结合各类物资的具体属性特征,设计不同的物资需求预测方法,提高预测精度,另外,也可针对不同物资制定差异化的物资管理策略,提高企业的运营效率。

### 3.3 模型评估

将采用本文方法得到的结果与使用 PCA-SOFM 神经网络和单独使用 SOFM 神经网络所得到的结果作对比分析见表5。

表5 三种方法聚类效果对比分析

方法	SOFM输入变量个数	平均轮廓系数	模型评价
NPCA-SOFM	4	0.87	最优
PCA-SOFM	6	0.63	较好
SOFM	8	0.54	一般

由表5可知,采用三种方法进行聚类的平均轮廓系数分别为0.87、0.63和0.54,可看出本文所采用的NPCA-SOFM神经网络模型聚类效果要优于PCA-SOFM模型和单独使用SOFM模型;且NPCA算法使得SOFM神经网络输入变量个数更少,降维效果更具优势,较好的提高了聚类性能。因此,本文所设计的基于NPCA-SOFM算法的电力物资细分模型是合理的,且具有明显的性能优势。

## 4 结语

文章结合NPCA和SOFM两种算法优缺点,设计了基于NPCA-SOFM算法的电力物资细分模型,首先,采用非线性主成份分析法NPCA将物资细分粗选指标转换为四个综合指标:重要性、紧急性、稀缺性和流通性,降低问题的复杂度;然后,构建基于SOFM神经网络算法的物资细分模型,通过算例分析对比分析,表明NPCA-SOFM神经网络算法性能更优,并将电力物资细分为四大类,为企业物资差异化需求预测和个性化库存管理提供参考意义,促进企业物资集约化管理和运营效益的提升。此外,本文主要研究了基于电力物资需求特性的物资细分模型,但是基于该分类的差异化需求预测方法及合理库存方案还有待进一步认真研究。

### 参考文献

- 张运洲,程路.中国电力“十三五”及中长期发展的重大问题研究.中国电力,2015,48(1):1-5.
- 邵康.物资管理信息系统在电力企业的应用.电力信息与通信技术,2015,13(8):70-73.
- Milosevic M, Valter Mcconville KM, Sejdic E, et al. Visualization of trunk muscle synergies during sitting perturbations using self-organizing maps (SOM). IEEE Trans. on Biomedical Engineering, 2012, 59(9): 2516-2523. [doi: 10.1109/TBME.2012.2205577]
- 蔡国伟,孙正龙,孔令国,等.基于两步聚类法的受扰机群同调性分析.中国电力,2013,46(2):46-49.
- 沈男.基于改进BP神经网络的电网物资需求预测研究[硕士学位论文].北京:华北电力大学,2014.
- 高新华,严正.基于主成分聚类分析的智能电网建设综合评价.电网技术,2013,37(8):2238-2243.
- 洪芳华,高峻峻,陆爽.基于需求特性分类的电力物资库存管理策略设计.物流技术,2011,30(9):212-216.
- 胡雷钧,庞松涛,朱炯,等.基于FPGA的大数据K-means算法优化.电力信息与通信技术,2016,14(8):1-6.
- 尹柏强,何怡刚,朱彦卿.一种广义S变换及模糊SOM网络的电能质量多扰动检测和识别方法.中国电机工程学报,2015,35(4):866-872.
- 单英浩,付青,耿炫,等.基于改进BP-SVM-ELM与粒子化SOM-LSF的微电网光伏发电组合预测方法.中国电机工程学报,2016,36(12):3334-3342.
- 孙鹏,曹雨晨,刘洋,等.采用二进制蚁群模糊神经网络的配电网故障分类方法.高电压技术,2016,42(7):2063-2072.