

# 运用模糊神经网络来区分变压器励磁涌流和内部故障

潘荣贞, 郁惟镛, 蔡华嵘

(上海交通大学电气工程系, 上海 200240)

**摘要:** 变压器励磁涌流和内部故障的鉴别一直是变压器差动保护中的一个热点问题。在几种传统的识别励磁涌流方法的基础上, 结合模糊神经网络这一新型的人工智能技术, 综合利用这几种原理对电气量的采样值分别提取形成网络的特征输入量, 并采用了 Simpson 模糊极小 - 极大神经网络来形成区分励磁涌流和内部故障的模糊模式分类器。运用 EMTP 程序通过大量的仿真计算获取网络的训练和测试样本, 结果表明, 训练后的网络能快速地区分变压器各种运行工况下的励磁涌流和内部故障, 对测试样本的正确率达到 100%。

**关键词:** 励磁涌流; 内部故障; 模糊极小 - 极大神经网络; 超盒; 多特征输入量

**中图分类号:** TM771 **文献标识码:** A **文章编号:** 1003-4897(2001)12-0008-05

## 1 引言

如何正确地区分励磁涌流和内部故障是变压器差动保护要解决的首要问题, 到目前为止, 国内外有关文献上已提出了多种鉴别励磁涌流和内部故障的方法<sup>[1][2]</sup>, 主要有以下几种: (1) 二次谐波原理; (2) 间断角原理; (3) 波形对称原理<sup>[3][4]</sup>; (4) 高频分量原理; (5) 磁通特性原理; (6) 等值电路原理; (7) 低电压加速判据; (8) 差动功率原理<sup>[5]</sup>。这些方法虽然都基于不同的原理在一定条件下能对励磁涌流和故障电流作出识别, 但由于它们都基于单一的特征量, 不能识别出所有情况 (例如变压器空载合闸于内部故障或变压器带分布电容长线发生内部故障等运行工况) 下的励磁涌流和故障电流, 其中部分算法在实际应用中遇到困难。近来, 国内外学者已将神经网络和模糊逻辑等技术应用到这一领域中<sup>[6]</sup>。但是人工神经网络存在学习训练过程困难以及网络结构难于被人理解等缺陷, 而模糊逻辑系统运用易于被人理解的模糊规则和推理机来描述一个分类系统, 但是如何确定隶属度和形成模糊推理规则是它的两大难点。本文拟运用模糊神经网络这一新型的人工智能技术来实现励磁涌流和内部故障的鉴别, 模糊神经网络将模糊推理系统用神经网络的结构来实现, 它利用神经网络的学习计算功能来形成隶属度和模糊推理规则, 因而结合了两者的优点, 这样的网络结构已被证明具有极强的模糊模式分类功能。

## 2 基于模糊极小 - 极大神经网络的鉴别算法原理

### 2.1 Simpson 模糊极小 - 极大神经网络原理及学习算法

本文将运用 Simpson 模糊极小 - 极大神经网络 (FMMNN) 来识别变压器的励磁涌流和内部故障, 这类模糊神经网络是由 Simpson [1992] 首先提出的<sup>[7]</sup>, 它的基本思想是运用超盒模糊集来定义隐含层的模糊神经元, 每个超盒代表一个模式类在样本空间中的一块区域。一个  $n$  维的模糊超盒是由  $n$  维空间中的一个极小点和一个极大点来定义的, 称为极小 - 极大超盒, 超盒内的点属于该超盒的隶属度为 1, 而超盒外的点属于该超盒的隶属度随着离超盒中心的距离的增加而减小, 由特定的隶属函数来定义。一个三维的超盒如图 1 所示。

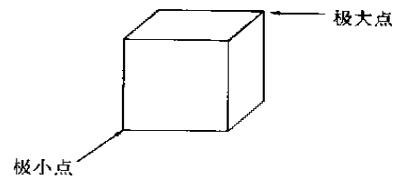


图1 极小 - 极大超盒

网络中的第  $j$  个超盒节点表示为:

$$B_j = \{ x, j, w_j, \mu_{B_j}(x, j, w_j) \} \quad (1)$$

则第  $k$  个模式类 (即网络的第  $k$  个输出) 可定义为:

$$C_k = \bigcup_j B_j \text{ 或 } \mu_{C_k}(x) = \max_j \mu_{B_j}(x) \quad (2)$$

$$\mu_{B_j}(x) = \frac{1}{n} \prod_{i=1}^n [1 - \max(0, \min(1, (x_i - w_{ji}) - \max(0, \min(1, (v_{ji} - x_i)))))] \quad (3)$$

$x = [x_1, x_2, \dots, x_n]^T$  为输入样本模式;

$j = [j_1, j_2, \dots, j_n]^T$  为  $B_j$  的极小点;

$w_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T$  为  $B_j$  的极大点;

$x_j, w_j$  均为  $n$  维空间中的向量。

$\mu_{B_j}$  为样本属于超盒  $B_j$  的隶属度值;

$\mu_{C_k}$  为样本属于模糊模式类  $C_k$  的隶属度值;

为灵敏度参数,表示隶属度值随  $x$  与  $B_j$  的距离增加时的下降速度,根据训练时的需要选取 0 到 1 之间的一个常数。

由上述超盒节点构成隐含层,加上代表模式样本的输入层和代表类别的输出层形成的三层结构的模糊极小-极大分类神经网络。

其中代表超盒  $B_j$  的超盒节点  $b_j$  的结构如图 2 所示:

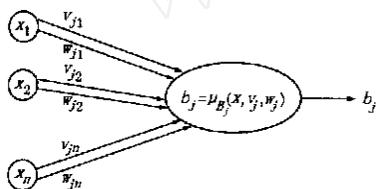


图 2 单个超盒节点的结构

$\mu_{kj} = \begin{cases} 1 & \text{如果 } b_j \text{ 是属于类 } k \text{ 的一个超盒} \\ 0 & \text{如果 } b_j \text{ 不是属于类 } k \text{ 的一个超盒} \end{cases}$  为超盒层到输出层的权值。

输出  $y_k = \max_{j=1}^n \mu_{kj} b_j$  表示样本  $x$  属于类  $k$  的隶属度

$w$  称为双重权值(dual weight),分别代表超盒节点的极小点和极大点矩阵,可运用模糊极小-极大学习算法来调整。

模糊极小-极大学习训练算法进行权值调整实际上是一个超盒的扩张-收缩过程,分为三步:

#### · 步骤 1 (超盒扩张)

对于一个训练样本对  $\{x_k, d_k\}$ ,如果代表与  $d_k$  相同的类的超盒满足式(6)就由式(7)来调整该超盒的极小点和极大点;如果没有一个超盒能满足式(6),就在网络中增加一个新的超盒节点  $B_j$ ,并按式(8)设置其权值向量,新增加的超盒节点  $B_j$  被分配到同一类中;网络的初始超盒节点数为零。

$$n \max_{i=1}^n [\max(w_{ji}, x_i) - \min(w_{ji}, x_i)] \quad (6)$$

$n$  为超盒的维数,  $0 < \alpha < 1$ 。

$$\begin{aligned} w_{ji}^{\text{new}} &= \min(w_{ji}^{\text{old}}, x_{ki}), w_{ji}^{\text{new}} = \max(w_{ji}^{\text{old}}, x_{ki}), \\ i &= 1, 2, \dots, n \end{aligned} \quad (7)$$

$$w_j = w_j = x_k \quad (8)$$

#### · 步骤 2 (超盒重叠测试)

检查代表不同类的超盒之间是否存在重叠;根据式(9)来确定超盒  $B_j$  和  $B_k$  是否重叠(假设它们代表不同的类):

$$\max_{i=1}^n (0, x_{ki} - w_{ji}) > 0 \quad (9)$$

假设上式成立,那么超盒  $B_j$  的极大点就包含在超盒  $B_k$  中,则必须通过超盒收缩来消除这种重叠。

#### · 步骤 3 (超盒收缩)

如果代表不同类的超盒之间存在重叠,通过最小地调整每个超盒来消除重叠(参阅文献<sup>[7]</sup>)。

对于满足式(9)的两个超盒,可以利用式(10)来调节超盒  $B_j$  的极大点,同时利用式(11)来调节超盒  $B_k$  的极小点。

$$w_{ji}^{\text{new}} = w_{ji}^{\text{old}} - \max(0, \frac{w_{ji} + x_{ki}}{2}) \quad (10)$$

$$w_{ki}^{\text{new}} = w_{ki}^{\text{old}} + \max(0, \frac{w_{ji} + x_{ki}}{2}) \quad (11)$$

## 2.2 鉴别算法的基本原理

变压器在励磁涌流和内部故障两种情况下都可以在差动保护中引起较大的差动电流,两者间的差别可以通过各自的特征量体现出来,因为各个特征量分别在一定程度上表达了励磁涌流和内部短路电流的差别。本文中我们利用模糊极小-极大网络很强的模糊模式识别和匹配功能来实现这一点,即通过提取励磁涌流和内部故障这两种情况下电压和电流波形的多个特征量,输入到网络中,每个特征量作为超盒的一维,只要励磁涌流和内部故障电流在一个或多个特征量上存在差别,那么在  $n$  维样本空间中这些特征量就会落在不同的超盒之中,利用网络的并行计算功能和模糊分类功能,通过学习在超盒层形成多条模糊判别规则,通过输出层输出的结果(类隶属度值)来作为励磁涌流和故障电流的识别的最终依据。

## 2.3 网络模型

我们采用了上述 Simpson 模糊极小-极大神经网络来作为本算法的基本网络构造模型。网络的输入层节点分别对应于各个特征量,则超盒的维数就等于特征量数;隐含层(也称为超盒层)中的节点数(即超盒数,对应于模糊规则数)由训练过程最终确定;输出层有两个节点:Class[0],Class[1],分别对应输入样本属于内部故障和励磁涌流的隶属度。这样网络的应用模型如图 3 所示。

其中各特征输入量的提取原理及方法如下:

#### (1) 二次谐波含量

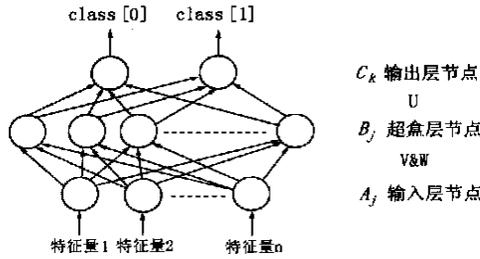


图3 应用于鉴别的网络结构

励磁涌流中含有较大的偶次谐波分量,其中二次谐波分量最大,一般较故障情况的谐波含量大。通过傅氏滤波提取差动电流中的基波  $I_{d1}$  和二次谐波  $I_{d2}$ ,  $k_{d2} = I_{d2}/I_{d1}$  即二次谐波含量。

(2) 五次谐波含量

同二次谐波含量取法,五次谐波含量  $k_{d5}$  可反映变压器是否处于过励磁状态。

(3) 波形对称程度

波形对称原理是对变压器电流进行分析的一种方法。由文献<sup>[4]</sup>的论述可以知道,在滤除直流分量后,故障电流的前半波和后半波要较励磁涌流的前后半波对称。所以将滤除直流分量(即微分)后的差流的前半波和后半波作对称性比较,将对称度作为特征量输入网络。对称度的定义式由下式给出:

$$k_i = \frac{I_i + I_{i+N/2}}{I_i + I_{i+N/2}} \quad (12)$$

其中,  $I$  为微分后的电流值。

为避免波形的毛刺,将半周波的平均对称程度作为特征量输入到网络中,即

$$k = \frac{2}{N} \sum_{i=1}^{N/2} k_i \quad (13)$$

其中,  $N$  为每周波采样点数。

(4) 三相低电压侧电压

此即电压制动原理。当变压器因励磁涌流出现严重饱和时,端电压会出现畸变,其中包含较大的谐波分量;而内部故障时,变压器的端电压会降到较低的水平,这样就可以用来作为鉴别励磁涌流和故障电流的特征量之一。

(5) 差动功率

该方法特别适用于高电压等级网络。正常情况及有大励磁电流的情况下,流入变压器的平均功率都较小(尽管暂态功率可能会很大)。而故障情况下因为有较大的铜耗,流入变压器的平均功率会大大增加。因此可以作为网络的一个判据输入。计算公式如下<sup>[5]</sup>:

$$W(t) = \frac{1}{T} \int_{t-T}^t (V_1 I_1 + V_2 I_2 - R_1 I_1^2 - R_2 I_2^2) dt \quad (14)$$

其中,  $V_1, V_2, I_1, I_2$  为变压器一次侧和二次侧的电压电流瞬时值。实际所用的是电压电流的采样点值,所以公式改写如下:

$$\text{瞬时功率 } p(t) = V_1 I_1 + V_2 I_2 - R_1 I_1^2 - R_2 I_2^2 \quad (15)$$

$$\text{平均功率 } W(t) = \frac{1}{T} \sum_{n=0}^{N-1} \{ p(t - \frac{n}{N} T) \} \quad (16)$$

$N$  为每周波采样点数。

对应于变压器会出现各种对称及不对称故障,各特征量都取三相值。因此,网络的15个特征输入量分别是:  $k_{d2A}, k_{d2B}, k_{d2C}, k_{d5A}, k_{d5B}, k_{d5C}, k_{1A}, k_{1B}, k_{1C}, U_A, U_B, U_C, W_A, W_B, W_C$ 。

3 网络的训练

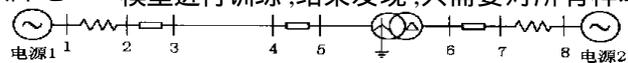
为使网络能实现所要求的功能,需对网络进行训练。本次训练采用的学习算法采用文献<sup>[7]</sup>中的模糊极小-极大学习算法。训练要求给网络提供尽可能广的训练样本,以适应各种情况。

3.1 用 EMTP 获取网络的训练样本

仿真时采用的变压器线路模型如图4所示。采样频率  $N = 20$  点/周,数据窗长度取一周波。仿真时所考虑的故障情况包括长线(150km)、短线(50km);轻载、重载;变压器内部(高压侧)单相接地短路、两相短路、两相接地短路、三相短路及故障时的不同过渡电阻;考虑了带长短线的空载合闸;考虑了空载合闸于各种内部故障类型。上述各种情况组合共计424种。为防止保护误动或拒动,每种情况又延迟了十个数据窗。得到4240个样本。对样本进行预处理时,首先提取各特征量,还要将每个输入量线性化归算到闭区间 $[0, 1]$ 内。

3.2 训练结果

对以上获取的训练样本运用 Simpson 网络的应用模型进行训练,结果发现,只需要对所有样本迭代一



电源1:  $U_N = 525\text{kV}$ , 系统阻抗为:  $X_0 = 9.3, X_1 = 2.7$ ,

电源2:  $U_N = 110\text{kV}$ , 系统阻抗为:  $X_0 = 16.3, X_1 = 8.07$

线路:  $Z_0 = 0.1717 + j0.6407, C_0 = 0.0021\mu\text{F}/\text{km},$

$Z_1 = 0.02 + j0.28 / \text{km}, C_1 = 0.0129\mu\text{F}/\text{km}$

变压器: 接线方式:  $Y_0 - /11$  点钟接法, 额定功率: 1125MVA, 电压比: 525kV/110kV,

高压侧漏抗:  $X = 18.32, R = 1.47$ , 低压侧漏抗:  $X = 2.413, R = 0.194$

图4 变压器及线路系统一次侧模型

次就可以获得满意的结果,共生成 113 个超盒,而且属于不同类的超盒之间没有出现重叠情况。一组典型样本的训练结果如表 1 所示:

表 1 一组样本的训练结果

类 型	Class[0]	Class[1]
高压侧单相短路	1.0000	0.2867
高压侧两相短路	1.0000	0.2024
高压侧两相短路接地	1.0000	0.3014
高压侧三相短路	1.0000	0.2983
高压侧三相短路接地	1.0000	0.2617
低压侧单相短路	1.0000	0.1987
低压侧两相短路	1.0000	0.2531
低压侧两相短路接地	1.0000	0.3102
低压侧三相短路	1.0000	0.2979
低压侧三相短路接地	1.0000	0.3059
空载合闸高压侧单相短路	1.0000	0.4109
空载合闸高压侧两相短路	1.0000	0.3911
空载合闸高压侧两相短路接地	1.0000	0.5556
空载合闸高压侧三相短路	1.0000	0.4025
空载合闸高压侧三相短路接地	1.0000	0.4124
空载合闸低压侧单相短路	1.0000	0.4863
空载合闸低压侧两相短路	1.0000	0.4352
空载合闸低压侧两相短路接地	1.0000	0.3815
空载合闸低压侧三相短路	1.0000	0.3614
空载合闸低压侧三相短路接地	1.0000	0.3251
空载合闸	0.3747	1.0000

从表 1 中类别隶属度可以很明显地区分出训练样本的类别。训练过程中也曾试过不加低压侧电压的输入方案,结果不能成功地实现分类,可见,电压判据在分类性能中占的比重还是很大的。

#### 4 网络的测试

同样利用 EMTP 仿真程序,按照训练样本的覆盖情况,随机改变合闸角度,做出 149 个样本,同样对每个样本移动十个数据窗,得到 1490 个测试样本,对网络进行测试。对输出结果的处理是通过比较隶属函数值的大小来判别属于哪个类别,对某一样本情况,连续三次判为同一类时,就判定为该类,否则继续判断。部分测试结果如表 2 所示。

从表 2 中可以看出,输出的两类隶属度可以很明显地鉴别出励磁涌流和内部故障的情况。

表 2 部分样本测试结果

类 型	Class[0]	Class[1]
高压侧单相短路	0.984	0.564
高压侧两相短路	0.996	0.434
高压侧两相短路接地	0.997	0.563
高压侧三相短路	0.996	0.487
高压侧三相短路接地	0.990	0.564
低压侧单相短路	0.988	0.523
低压侧两相短路	1.000	0.464
低压侧两相短路接地	0.997	0.527
低压侧三相短路	0.996	0.538
低压侧三相短路接地	0.989	0.486
空载合闸高压侧单相短路	1.000	0.664
空载合闸高压侧两相短路	0.997	0.627
空载合闸高压侧两相短路接地	0.996	0.670
空载合闸高压侧三相短路	0.989	0.621
空载合闸高压侧三相短路接地	0.993	0.654
空载合闸低压侧单相短路	0.956	0.747
空载合闸低压侧两相短路	0.983	0.769
空载合闸低压侧两相短路接地	1.000	0.737
空载合闸低压侧三相短路	1.000	0.677
空载合闸低压侧三相短路接地	1.000	0.630
空载合闸	0.695	0.984

#### 5 结论

本文在现有的各种区分变压器励磁涌流和内部故障的方法的基础上,提出了一种运用 Simpson 模糊极小-极大神经网络来鉴别励磁涌流和内部短路的新算法,该方法展示了模式分类和识别的一种新概念。网络模型的构造是基于各方法的判据中提取各自的特征量,然后综合作为网络的特征输入量,运用网络的模糊模式识别和匹配功能实现励磁涌流和内部故障的鉴别,并运用 EMTP 仿真获取大量样本进行训练和测试网络。训练算法的优点是:(1)主要运算是加、减和比较,计算简单迅捷;(2)不存在网络权值的收敛问题,只需对所有样本通过一遍或少数几遍的学习就可形成最终的权值;(3)在训练时能自动在网络中形成模糊规则来进行模糊模式匹配,网络具有极强的模糊分类和识别能力;(4)新的鉴别算法由于综合了多特征量,使得鉴别结果能自适应于变压器各种运行工况,而且鉴别结果准确;(5)算法中需用全波傅氏滤波,故鉴别时间为 20ms,基本满足差动保护快速

动作的要求,但还有待提高。

#### 参考文献:

- [1] 董洁,于莉萍,焦志先,许华乔. 变压器差动保护涌流制动原理的研究. 电力系统自动化,1997,12(12).
- [2] 王国兴,张传理,黄益庄. 变压器励磁涌流判别方法的现状及发展. 中国电力,1998,31(10):19-22.
- [3] 何奔腾,徐习东. 波形比较法变压器差动保护原理. 中国电机工程学报,1998,18(6).
- [4] 焦邵华,刘万顺. 区分变压器励磁涌流和内部短路的积分波形对称原理. 中国电机工程学报,1999,19(8).
- [5] Kuniaki Yabe. Power Differential Method for Discrimination between Fault and Magnetizing Inrush Current in Transformers. IEEE Transactions on Power Delivery, July 1997,12(3).
- [6] Perez L G, Flechsig A J, Meador J L, et al. Training an Artificial Neural Network to Discriminate Between Magnetizing Inrush and Internal Faults. IEEE Transactions on Power Delivery, 1994, 9(1): 434 - 441.
- [7] Patrick K Simpson. Fuzzy Min - Max Neural Networks - - Part 1: Classification. IEEE Transactions on Neural Networks, September 1992,13(5): 776 - 786.
- [8] Massimo Meneganti, Francesco S Saciello and Roberto Tagliarferri. Fuzzy Neural Network for Classification and Detection of Anomalies. IEEE Transactions on Neural Networks, September 1998,9(5): 848 - 861.

收稿日期: 2001-05-17; 改回日期: 2001-09-07

基金项目: 中华电力教育基金会许继奖教金资助项目

作者简介: 潘荣贞(1973-),男,博士研究生,研究方向为人工智能在继电保护中的应用。

### Use fuzzy neural network to discriminate transformer magnetizing inrush and internal faults

PAN Rong - zhen, YU Wei - yong, CAI Hua - rong  
(Shanghai Jiaotong University, Shanghai 200240, China)

**Abstract:** The discrimination between transformer magnetizing inrush and internal faults is a hot point in transformer differential protection. In this paper, based on several traditional methods to identify magnetizing inrush such as second harmonic theory, high harmonic theory, symmetry of wave shape theory, low voltage accelerating criterion and differential power theory, etc, and considering the new artificial intelligence technique of fuzzy neural network, we make full use of these theories and develop several corresponding characteristic inputs from electrical sampling values. Furthermore, we use Simpson's fuzzy min - max neural network to develop a fuzzy pattern classifier to discriminate between magnetizing inrush and internal faults. We also use EMTP simulation to get plenty of training and testing patterns. The training and testing result shows that the trained network can discriminate magnetizing inrush and internal fault quickly under all kinds of transformer operating conditions, the correct rate of testing samples is up to 100%.

**Keywords:** magnetizing inrush; internal faults; fuzzy min - max neural network; hyperbox; multi characteristic inputs