

人工神经网络方法实现自动判别失磁类型及失磁深度^{*}

刘一江 易理刚

(湖南大学 长沙 410082)

摘要 利用失磁后 $E_{t,q}$ 、 $E_{f,q}$ 衰减时间常数 T_q 仅取决于发电机参数及失磁类型的结论, 根据失磁故障的分类, 采用一个三层前向神经网络得出 T_q , 使微机失磁保护能够在失磁发生的瞬间自动判别出失磁类型并预测失磁深度。数字仿真、动模试验以及实际运行证明了本文所提出的方法。

关键词 失磁保护, 神经网络

分类号 TP1

The Study of Application of Artificial Neural Network on Failure-Mode Recognition and Loss-Degree-Prediction

Liu Yijiang Yi Ligang

(Hunan University, Changsha, 410082)

Abstract Using a conclusion of time-constant-attenuation after loss-of-excitation only decided by generator parameters and failure-modes, the paper according to the classify of loss-of-excitation faults, adopts a three-layer feed-forward neural network to obtain " T_q ". Which makes microcomputer-based Loss-of-Excitation protection in the twinkling of fault happening failure-mode-recognition and loss-degree-prediction. Figure simulating, trend imitate testing and action moving proved that the method raised is correct.

Key words loss-of-excitation protection, neural network

发电机失磁后, 不同类型故障所造成失磁程度不尽相同, 对系统和发电机产生危害程度也有很大差异。因此, 失磁保护对不同故障处理对策应该有所不同。传统发电机失磁保护方案, 如利用失磁后转子励磁回路电流、电压作为判据的失磁保护^[1], 利用失磁后发电机定子参数变化特点构成的失磁保护等, 都是基于反映发电机失磁时某个或某几个电气量超过或低于预定限度的突然变化, 由于一个或几个电气量很难完整地描述故障状态, 因此, 都只能简单地判断是否发生了失磁故障, 而不能判断究竟发生了什么样类型的失磁故障。

人工神经网络方法利用神经网络的自适应性和自学习性, 网络通过训练, 将自学会对输入向量的分析和推理, 进而实现计算、记忆、联想、识别等功能。本文基于人工神经网络的方法, 利用失磁后 $E_{t,q}$ 、 $E_{f,q}$ 衰减时间常数 T_q 仅取决于发电机参数及失磁类型的结论, 建立一个三层前向神经网络; 通过对各类失磁故障下的大量样本训练, 建立输入到输出的映射来获取 T_q , 以 T_q 来判别失磁类型, 并预测失磁深度。

1 $E_{t,q}$ 、 $E_{f,q}$ 判据特性和失磁故障的分类

根据 $E_{t,q}$ 、 $E_{f,q}$ 判据的基本概念^[2,3] 和各种失磁情况的 $E_{t,q}$ 和 $E_{f,q}$ 特性^[3] 分析知: ① $E_{t,q}$ 和 $E_{f,q}$ 不受滑差、电压波动和“储能效应”的影响, 其衰减时间常数 T_q 和 T_q 的大小仅取决于发电机参数及失磁故障类型, 与系统运行方式和发电机运行工况无关; ②失磁故障可分为两大类: 一类是故障发生瞬间 $E_{f,q}$ 突变(急剧下降), $E_{t,q}$ 按指数规律衰减, 称为冲击型失磁故障; 另一类是 $E_{f,q}$ 并不突降, 而以指数规律衰减, $E_{t,q}$ 由初值的 E 开始平滑地下降, 称为渐变型失磁故障, 这两类故障最具代表性的是主励回路短路及副励回路短路。

* 1999年4月30日收稿

第一作者: 刘一江, 男, 1956年生, 教授

2 基于神经网络方法的发电机失磁保护

2.1 对输入信号特征的提取

由于 $E_{t,q}$ 和 $E_{f,q,q}$ 不受滑差, 电压波动和“储能效应”的影响, 所以用这两种虚拟的物理量来判别失磁故障类型具有特殊的优越性。

根据分类, 所提取特征量为: 强制空载电势分量 $E_{f,q,q}$ 和强制同步电势分量 $E_{t,q}$ 。

2.2 神经网络结构的确定

2.2.1 神经网络结构的层数

本文采用一个三层前向神经网络来进行微机发电机失磁保护(如图1所示)。

隐含层中第 j 个节点的输出为

$$X_j^{(2)} = f(\text{Net}_j^{(1)})$$

$$\text{Net}_i^{(1)} = \sum_j W_{ij}^{(1)} \cdot X_i^{(1)} + q_i^{(1)}$$

$$U^* = f(\text{Net}_K^{(2)})$$

$$\text{Net}_j^{(2)} = \sum_k W_{jk}^{(2)} \cdot X_k^{(2)} + q_j^{(2)}$$

式中 $X_i^{(1)}$ 为网络输入特征量, 是网络的第 i 个输入量, 即输入层第 i 个节点输出。 $W^{(L)}$ 是表示第 $L-1$ 层到第 L 层之间连接权值, $X_j^{(L)}$ 表示第 L 层第 j 个神经元的输出, $q_j^{(L)}$ 表示第 L 层第 j 个节点的阈值, $L=1, 2$ 。传递函数 $f(Z) = 1/(1 + e^{-Z})$ 。

网络中各个神经元的阈值及各层神经元之间联接权值可通过对正常状态, 非正常工作状态和各种失磁状态等大量样本进行训练的过程来确定。

2.2.2 学习算法

为了提高训练时收敛速度, 采用反传学习算法, 即 BP 算法。学习过程由正向传播和反向传播组成^[4]。

2.2.3 网络的输入与输出

根据文献^[3], 以影响各种失磁情况下 $E_{t,q}$ 和 $E_{f,q,q}$ 特性方程的有关参量 U_{fd} (转子电压)、 U_{fdo} (定载转子电压)、 P 、 Q (有功、无功)、 R 、 X (励磁回路的电阻、电抗)、 U_h 、 U (高压侧测量电压、机端电压幅值)、 I (定子电流) 作为网络的输入(除 U_{fd} 外, 其余量由电流电压采样值算出); 通过各种失磁情况下各相关参量的变化方程求得 $E_{t,q}$ 和 $E_{f,q,q}$ 的特性方程, 得到 $E_{t,q}$ 和 $E_{f,q,q}$, 并进行输入数据预处理, 获得网络输入节点值。

由于采用 S 形函数, 网络输出节点值为 0~1; 而建立网络模型的目的是为了判别失磁类型及深度, 因此, 输出层节点数为 1 个。

3 人工神经网络的训练和测试

就发电机各种失磁故障, 纵轴同步电抗 X_d 取 1.867, 系统联系阻抗 X_{st} 分取为 0.35, 0.5 和 0.9, P_0 为 0.25, 0.5, 0.75 和 1.0 时, 对 $E_{t,q}$ 、 $E_{f,q,q}$ 的衰减时间常数 T_q 做仿真计算, 以此建立 BP 网络训练和测试的样本集。

3.1 网络训练

3.1.1 选取训练样本集

选取训练样本时, 尽量覆盖各种故障情况, 故障选取如表 2、表 3 所示的 13 种故障类型。

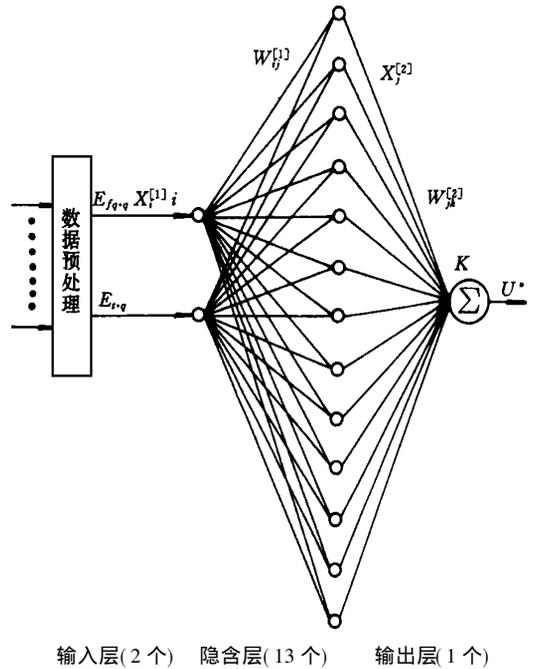


图1 三层前向神经网络

Fig. 1 Three-layer free-forward neural network

3.1.2 输入数据预处理

由各种失磁故障情况 $E_{t,q}$ 、 $E_{f,q}$ 特性方程, 求得的 $E_{t,q}$ 、 $E_{f,q}$ 特征量, 在进入神经网络之前, 需对其进行输入数据预处理, 处理后的数据值为 $[-6, 6]$ 之间、级差为 1 的整数, 从而得到神经网络输入层对应失磁下各节点数值。

3.1.3 人工神经网络的训练

训练样本确定后, 开始对所建立的神经网络模型进行学习训练, 学习算法采用前文所述反传学习算法 (BP 算法), 通过训练样本对网络进行训练, 从而得到网络的权值矩阵和阈值矩阵。

3.1.4 网络的形成

通过训练, 形成如图 1 所示的网络。

3.1.5 仿真计算结果(以最具代表性的主励回路短路及副励回路短路为例)

仿真结果如表 1。

表 1 T_q 在不同的 X_{st} 、 P_o 的仿真计算结果

Tab. 1 The results of simulating calculations of " T_q " in different " X_{st} ", " P_o "

序号	X_d	X_{st}	P_o	主励回路短路			副励回路短路		
				$E_{t,q}$ 衰减 时间常数 期望值	$E_{t,q}$ 衰减 时间常数 输出值	相对误 差%	$E_{f,q,q}$ 衰减 时间常数 期望值	$E_{f,q,q}$ 衰减 时间常数 输出值	相对误 差%
				$T_{d,q(s)}$	$T_{q(s)}$		$T_{L,q(s)}$	$T_{q(s)}$	
1	1.867	0.35	1.00	0.333	0.325	0.8	0.999	0.9589	4.01
2	1.867	0.35	0.5	0.333	0.3135	1.95	0.999	0.9453	5.37
3	1.867	0.5	1.00	0.333	0.3137	1.93	0.999	0.9801	1.89
4	1.867	0.5	0.5	0.333	0.3186	1.44	0.999	0.9539	4.51
5	1.867	0.9	1.00	0.333	0.3161	1.69	0.999	0.9807	1.83
6	1.867	0.9	0.5	0.333	0.3298	1.32	0.999	0.9825	1.65

注 X_d : 发电机纵轴同步电抗, X_{st} : 发电机与系统联系阻抗。

期望值 0.333、0.999 是取 S 型函数输出 0~1 之间对应故障下期望达到的数值, 下同。

由仿真结果看, 当确定的机组发生同一类型的失磁故障时, T_q 基本上具有确定的值, 且不随系统联系阻抗 X_{st} 及发电机运行工况(这里取 P_o) 的改变而变化(不计误差)。另外, 不同类型故障的 T_q 亦不同, T_q 的输出值与期望值也是基本吻合的, 仅有较小的误差。

P_o 为 0.25、0.75 的仿真计算结果, 限于篇幅从略。

3.2 网络测试

以研制的微机式失磁保护系统为样机, 对综合 T_q 判别失磁故障类型的人工神经网络方法进行测试。测试结果如表 2、表 3。

表 2 冲击型失磁类型的自动识别

Tab. 2 Rush type of failure-mode-recognition

序号	测试项目	T_q 期望值	T_q 实际输出值	相对误差%
1	主励回路开路	0.05	0.045	-0.5
2	放电电阻灭磁方式下灭磁开关误掉闸	0.15	0.161	1.1
3	灭孤栅灭磁方式下灭磁开关误掉闸	0.20	0.186	-1.4
4	交流机带静止可控硅方式下励磁调节器故障使励磁系统处于逆变状态	0.30	0.292	-0.8
5	主励回路短路	0.333	0.325	-0.8
6	可控硅方式的调励器故障引起的部分失磁及其他主励故障引起的部分失磁	0.450	0.448	-0.2
7	副励回路开路	0.666	0.645	-2.1
8	副励机自动恒压环节短路	0.1	0.118	1.8

表3 渐变型失磁故障类型的自动识别
Tab.3 Gradual change type of failure- mode- recognition

测试项目	T_q 期望值	T_q 实际输出值	相对误差%
旋转硅整流励磁方式下灭磁开关误掉闸	0.9	0.898	- 0.2
副励回路短路	0.999	0.995	- 0.4
他励静止硅整流方式副励自励恒压环节开路	0.8	0.802	+ 0.2
备励失压	0.75	0.753	+ 0.3
副励系统自励调压器或硅整流系统故障及其他励系统故障引起的部分失磁	0.7	0.705	+ 0.5

4 结论

(1) 同机组同一类型失磁故障下, $E_{t,q}$ 和 $E_{f,q,q}$ 具有确定的衰减率, 即衰减时间常数 T_q 具有确定值, 其大小仅次于发电机参数及失磁故障的类型, 与系统运行方式及发电机运行工况无关。

(2) 根据失磁发生时, $E_{t,q}$ 、 $E_{f,q,q}$ 的特点及 T_q 的大小, 构筑的微机型三层前向神经网络式保护, 可实现自动判别失磁故障的类型并预测失磁深度。因此, 根据故障类型可选择最佳动作方案, 为现场处理故障及事故的分析提供重要依据, 为防止故障扩大赢得时间。

参考文献

- 1 陈德树. 计算机继电保护原理与技术. 北京: 水利电力出版社, 1991: 150~153
- 2 林韩, 邱国义. 以新的虚拟物理量 $E_{t,q}$ 、 $E_{f,q,q}$ 为判据的新型计算机失磁保护. 电力系统自动化, 1989; 13(4): 52~60
- 3 林韩, 邱国义. 微机保护实现自动差别失磁类型和预测失磁深度. 中国电机工程学报, 1993. 5(13): 1~9
- 4 韩祯祥, 文福栓. 人工智能及其在电力系统中的应用- 从专家系统到人工神经网络. 电力系统自动化, 1991; 3(15): 5~14
- 5 王耀南著. 智能控制系统——模糊逻辑专家系统神经网络控制. 长沙: 湖南大学出版社, 1996, 357~361