

# 基于耦合隐马尔可夫模型的输电线路状态评估

葛夕武<sup>1</sup>, 朱超<sup>2</sup>, 马骏毅<sup>3</sup>, 刘强<sup>1</sup>, 梁晟杰<sup>1</sup>, 吴国梁<sup>1</sup>

(1. 南京供电公司, 江苏 南京 210008;

2. 河海大学 能源与电气学院, 江苏 南京 210098;

3. 镇江供电公司, 江苏 镇江 212001)

**摘要:** 架空输电线路是输电网络的重要组成部分, 其运行状态将直接影响整个输电系统的运行可靠性。为了更好地掌握架空输电线路的运行状态, 需要准确地对其进行状态评估。为此, 提出了一种基于人工智能的机器学习方法—耦合隐马尔可夫模型来对架空输电线路进行状态评估。根据评估要求收集架空输电线路在正常、注意、异常、严重四种状态下的历史评估数据并将数据进行归一化处理。利用该人工智能算法对归一化后的四类数据进行模型训练, 得到四组不同状态下的模型参数, 建立起正常、注意、异常、严重四个状态的耦合隐马尔可夫模型。将归一化后的评估数据带入建立好的四组模型当中, 得到四个状态评估值, 其中评估值最大的该组模型所对应的状态组别就是评估数据所反映的线路状态。采用该机器学习模型对某条架空输电线路进行实证分析和评估, 并将评估结果与实际的监控情况进行比较。分析和评估结果表明, 所提出的方法具有一定的实用性和可行性。

**关键词:** 人工智能; 机器学习; 耦合隐马尔可夫模型; 状态评估

中图分类号: TP302

文献标识码: A

文章编号: 1673-629X(2017)04-0164-06

doi: 10. 3969/j. issn. 1673-629X. 2017. 04. 037

## State Evaluation of Transmission Line Based on Coupled Hidden Markov Model

GE Xi-wu<sup>1</sup>, ZHU Chao<sup>2</sup>, MA Jun-yi<sup>3</sup>, LIU Qiang<sup>1</sup>, LIANG Sheng-jie<sup>1</sup>, WU Guo-liang<sup>1</sup>

(1. Nanjing Power Supply Company, Nanjing 210008, China;

2. College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China;

3. Zhenjiang Power Supply Company, Zhenjiang 212001, China)

**Abstract:** Overhead transmission line is an important part of the transmission network. The running state will directly affect the reliability of the operation of the whole power system. In order to learn the running state of the transmission line exactly, it is needed to evaluate the line accurately. A machine learning method based on artificial intelligence called Coupled Hidden Markov Model (CHMM) has been proposed for the assessment of the state of the overhead transmission line. According to the assessment demand, the historical assessment data of overhead transmission line under normal, abnormal, attention, serious four kinds of state are collected, and the data are normalized. The artificial intelligence algorithm is used to train the normalized four kinds of data to obtain the model parameters of the four groups and four states have been established for the CHMM. The normalized test data are brought into the four sets of models, and the four state evaluation values are obtained, in which the maximum value of the model is the state of the test data. This machine learning model is applied to conduct the empirical analysis and an overhead transmission line is evaluated, compared with the result of the assessment and the actual monitoring. The result of analysis and estimation shows that the method is effective and feasible.

**Key words:** artificial intelligence; machine learning; coupled hidden Markov model; state evaluation

## 0 引言

架空输电线路是电网的重要组成部分, 其运行状态的好坏, 会对整个输电系统运行的可靠性产生较

大影响。

目前, 有关架空输电线路状态评估的研究已经取得了一定的研究成果。文献[1-4]基于线路元件可靠

收稿日期: 2016-05-05

修回日期: 2016-08-12

网络出版时间: 2017-03-07

基金项目: 国家电网公司总部科技项目(PD71-14-041)

作者简介: 葛夕武(1980-), 男, 工程师, 硕士, 从事配电网规划工作。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20170307.0920.018.html>

性模型对架空输电线路进行了研究,其分析过程由状态选择、状态估计和指标计算三个步骤组成。文献[5-9]建立的线路系统风险评估模型相对于线路元件可靠性模型,是一种短时间尺度的评估模型。它通过将时变的线路元件故障率模型代入线路系统风险评估模型,得到线路系统风险评估指标,以风险评估指标值表征线路的运行状况好坏。然而,可靠性模型和风险评估模型都是以单一的线路元件模型代替整个评估系统,难以完全体现架空输电线路这样多层次多指标的复杂系统的真实状态。文献[10-11]提出一种基于贝叶斯网络的架空输电线路状态评估模型,不仅能够得出架空输电线路及其各部件的运行状态概率,而且还可以利用贝叶斯网络的双向推理技术方便地求解各部件对整条线路运行状态的影响。但是,基于贝叶斯网络的评估模型,是一种在概率统计基础上的评估模型,它对原始数据的要求较高,且在模型训练时,容易陷入局部最优解。

为此,文中提出了一种基于人工智能的机器学习方法——耦合隐马尔可夫模型来对架空输电线路进行状态评估。根据评估要求收集架空输电线路在正常、注意、异常、严重四种状态下的历史评估数据并将数据进行归一化处理。利用耦合隐马尔可夫算法对归一化后的四类数据进行模型训练,得到四组不同状态下的模型参数,建立起四个状态的耦合隐马尔可夫模型。将归一化后的测试数据带入建立好的四组模型当中,得到四个状态评估值,其中评估值最大的该组模型所对应的状态组别就是测试数据所反映的线路状态。

## 1 隐马尔可夫模型

隐马尔可夫模型(Hidden Markov Model, HMM)是20世纪60年代建立的统计分析模型。作为一种机器学习方法,适用于随机过程时间序列的建模<sup>[12-14]</sup>,特别适用于重复再现性不佳、非平稳的信号识别,由于其自适应的学习能力,在语音识别、人脸识别和故障诊断等领域应用广泛<sup>[15-17]</sup>。

当HMM的观测值为离散值时,可用以下参数进行表述:

(1)  $N$ :模型的隐状态数。记 $N$ 个隐状态为 $S_1, S_2, \dots, S_N$ ,模型 $t$ 时刻所处的状态为 $q_t$ ,则有 $q_t \in (S_1, S_2, \dots, S_N)$ 。

(2)  $M$ :每个隐状态对应的离散观测值数目。记 $M$ 个观测值为 $V_1, V_2, \dots, V_M$ , $t$ 时刻的观测值为 $o_t$ ,则有 $o_t \in \{V_1, V_2, \dots, V_M\}$ 。

(3)  $A$ :状态转移矩阵, $A = \{a_{ij}\}$ 。其中, $a_{ij} = P(q_{t+1} = S_j | q_t = S_i)$ , $1 \leq i, j \leq N$ 。

(4)  $B$ :观测值概率矩阵, $B = \{b_j(k)\}$ 。其中, $b_j(k) = P(o_t = v_k | q_t = S_j)$ , $1 \leq j \leq N, 1 \leq k \leq M$ 。

(5)  $\pi$ :初始状态概率向量, $\pi = \{\pi_i\}$ 。其中, $\pi_i = P(q_1 = S_i)$ , $1 \leq i \leq N$ 。

综上,一个HMM可以由参数 $N, M, A, B$ 和 $\pi$ 表示,简记为:

$$\lambda = (\pi, A, B) \quad (1)$$

## 2 耦合隐马尔可夫模型

由于使用HMM对非平稳过程进行建模时,它将非平稳过程看作多个平稳过程的串联,其中状态序列表示各平稳过程的交替,是一条马尔可夫链。而实际中将多源数据表示成一个参数受状态变量控制的多变量概率密度函数,因此要求多源数据对应的状态必须是同步的,这种单状态序列的贝叶斯网络结构限制了其多源信息融合的建模能力<sup>[18-19]</sup>。而耦合隐马尔可夫模型(Coupled Hidden Markov Model, CHMM)是一种可以描述两个或多个相互关联的随机过程的概率模型<sup>[20]</sup>,可以更加详尽地表述多源数据的统计特性。耦合隐马尔可夫模型也是一种机器学习方法,其系统参数能够随着训练数据的变化而自适应变化。

CHMM可以看作是多个HMM通过在状态序列之间引入耦合条件概率而得到的一种多马尔可夫链模型,适合用于对设备运行状态综合建模。该模型含有两条隐马尔可夫链,即具有两个HMM,且每个HMM都有一条状态序列和一条观测值序列。与HMM不同的是,CHMM中各HMM在 $t(t > 1)$ 时刻的状态不仅依赖于该HMM中 $t-1$ 时刻的状态,还依赖于所有与该HMM耦合的HMM中 $t-1$ 时刻的状态。因此,CHMM适合用于对两个或多个相互之间存在依赖或因果关系的随机过程进行建模。

一个含有两条链的CHMM可由下列参数描述<sup>[21-22]</sup>(记 $c$ 为链的序号, $c=1,2$ ):

(1)  $Q$ :模型的状态序列。由于模型由两条链组成,因此,任意时刻模型所处的状态为两条链分别所处的状态的组合。记第 $c$ 条链的状态数目为 $N_c$ ,那么,模型的状态数目为 $\sum_{c=1}^2 N_c$ 。记第 $c$ 条链的 $N_c$ 个状态为 $S_1^c, S_2^c, \dots, S_{N_c}^c$ , $t$ 时刻第 $c$ 条链所处的状态为 $q_t^c$ 。记模型的第 $i$ 个状态为 $S_i = \{S_{i_1}^1, S_{i_2}^2\}$ , $t$ 时刻模型所处的状态为 $q_t = \{q_t^1, q_t^2\}$ 。那么,模型的状态序列为:

$$Q = \{q_1, q_2, \dots, q_T\} = \{(q_1^1, q_1^2), (q_2^1, q_2^2), \dots, (q_T^1, q_T^2)\} \quad (2)$$

(2)  $O$ :模型的观测值序列。同样,模型的观测值序列也包含两条链的观测值序列。记 $t$ 时刻第 $c$ 条链

的观测值为  $o_t^c$ ,  $t$  时刻模型的观测值为  $o_t = \{o_t^1, o_t^2\}$ 。那么, 模型观测值序列为:

$$O = \{o_1, o_2, \dots, o_T\} = \{(o_1^1, o_1^2), (o_2^1, o_2^2), \dots, (o_T^1, o_T^2)\} \quad (3)$$

(3)  $\pi$ : 初始状态概率向量,  $\pi = \{\pi_i\}$ 。其中,  $\pi_i$  是  $t=1$  时刻模型处于状态  $S_i = \{S_{i_1}^1, S_{i_2}^2\}$  的先验概率, 即

$$\pi_i = \prod_{c=1}^2 \pi_{i_c}^c = \prod_{c=1}^2 P(q_1^c = S_{i_c}^c) \quad (4)$$

其中,  $\pi_{i_c}^c$  表示  $t=1$  时刻第  $c$  条链处于状态  $S_{i_c}^c$  的先验概率。

(4)  $A$ : 状态转移概率矩阵,  $A = \{a_{i,j}\}$ 。其中,  $a_{i,j}$  是模型从状态  $S_i = \{S_{i_1}^1, S_{i_2}^2\}$  转移到状态  $S_j = \{S_{j_1}^1, S_{j_2}^2\}$  的概率, 即

$$a_{i,j} = \prod_{c=1}^2 a_{i_c,j_c}^c = \prod_{c=1}^2 P(q_{t+1}^c = S_{j_c}^c | q_t^c = S_{i_c}^c) \quad (5)$$

其中,  $a_{i_c,j_c}^c$  表示给定前一时刻模型处于状态  $S_i = \{S_{i_1}^1, S_{i_2}^2\}$  的条件下, 当前时刻第  $c$  条链处于状态  $S_{j_c}^c$  的概率。

(5)  $B$ : 观测值概率分布。

$$b_j(o_t) = \prod_{c=1}^2 b_{j_c}^c(o_t^c) = \prod_{c=1}^2 P(o_t^c | q_t^c = S_{j_c}^c) \quad (6)$$

其中,  $b_{j_c}^c(o_t^c)$  表示给定链  $c$  处于状态  $S_{j_c}^c$  的条件下, 产生观测值  $o_t^c$  的概率。

使用高斯混合模型来描述连续型观测值概率密度函数。

$$b_{j_c}^c(o_t^c) = \sum_{m=1}^{M_j^c} c_{j,m}^c N(o_t^c, \mu_{j,m}^c, \Sigma_{j,m}^c) \quad (7)$$

其中,  $M_j^c$  是链  $c$  中状态  $S_{j_c}^c$  的高斯元数目;  $c_{j,m}^c$ 、 $\mu_{j,m}^c$  和  $\Sigma_{j,m}^c$  分别是链  $c$  中状态  $S_{j_c}^c$  的第  $m$  个高斯元的混合系数、均值向量和协方差矩阵。

CHMM 依然可以简记为  $\lambda = (\pi, A, B)$ , 文献 [21] 给出了通过期望值最大算法 (EM 算法) 进行参数重估的公式及步骤, 仅列出其重要公式:

前向变量初始化:

$$\begin{aligned} \partial_1(i) &= P(o_1^1, o_1^2, q_1 = s_i | \lambda) = \\ &= P(q_1 = s_i | \lambda) P(o_1^1 | q_1 = s_i, \lambda) = \\ &= \pi_i b_i(o_1) \end{aligned} \quad (8)$$

前向变量递推 ( $t = 2, 3, \dots, T$ ):

$$\begin{aligned} \partial_t(j) &= P(o_1^1, o_1^2, o_2^1, o_2^2, \dots, o_t^1, o_t^2, q_t = S_j | \lambda) = \\ &= \sum_i P(o_{1:t}, q_{1:t-1} = S_i, q_t = S_j | \lambda) = \\ &= \sum_i \partial_{t-1}(i) a_{i,j} b_j(o_t) \end{aligned} \quad (9)$$

后向变量初始化:

$$\beta_T(i) = 1 \quad (10)$$

后向变量递推 ( $t = T-1, T-2, \dots, 1$ ):

$$\begin{aligned} \beta_i(i) &= P(o_{t+1}^1, o_{t+1}^2, o_{t+2}^1, o_{t+2}^2, \dots, o_T^1, o_T^2 | q_t = S_i, \lambda) = \\ &= \sum_j P(o_{t+1:T}, q_{t+1} = S_j | q_t = S_i, \lambda) = \\ &= \sum_j a_{i,j} b_j(o_{t+1}) \beta_{t+1}(j) \end{aligned} \quad (11)$$

$$\begin{aligned} \xi_i^c(i, j) &= P(q_t = S_i, q_{t+1}^c = S_j^c | (O, \lambda)) = \\ &= \frac{\sum_{j \leq 1, j_c = j} \alpha_i(i) a_{i,j} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_k \alpha_i(k) \beta_t(k)} \end{aligned} \quad (12)$$

$$\begin{aligned} \gamma_i^c(j, m) &= P(q_t^c = S_j^c, x_{j,t}^c = S_{j,m}^c | O, \lambda) = \\ &= \frac{\sum_{j \leq t, j_c \neq j} \alpha_i(j) \beta_i(j) \frac{w_{j,m}^c N(o_t^c, \mu_{j,m}^c, \Sigma_{j,m}^c)}{\sum_k \alpha_i(k) \beta_i(k) \sum_n w_{j,n}^c N(o_t^c, \mu_{j,n}^c, \Sigma_{j,n}^c)}}{\sum_k \alpha_i(k) \beta_i(k)} \end{aligned} \quad (13)$$

$$\bar{\pi}_i^c = \sum_{m=1}^{M_i^c} \gamma_i^c(i, m) \quad (14)$$

$$\bar{a}_{i,j}^c = \frac{\sum_{t=1}^{T-1} \xi_i^c(i, j)}{\sum_{t=1}^{T-1} \sum_{k=1}^N \xi_i^c(i, k)} \quad (15)$$

$$\bar{w}_{j,m}^c = \frac{\sum_{t=1}^T \gamma_i^c(j, m)}{\sum_{t=1}^T \sum_{n=1}^{M_j^c} \gamma_i^c(j, n)} \quad (16)$$

$$\bar{\mu}_{j,m}^c = \frac{\sum_{t=1}^T \gamma_i^c(j, m) o_t^c}{\sum_{t=1}^T \gamma_i^c(j, m)} \quad (17)$$

$$\bar{\Sigma}_{j,m}^c = \frac{\sum_{t=1}^T \sum_{i=1}^N \gamma_i^c(j, m) (o_t^c - \mu_{j,m}^c) (o_t^c - \mu_{j,m}^c)^T}{\sum_{t=1}^T \gamma_i^c(j, m)} \quad (18)$$

其中,  $\xi_i^c(i, j)$  为在给定模型参数  $\lambda$  和观测值序列  $O$  的条件下,  $t$  时刻模型处于状态  $S_i = \{S_{i_1}^1, S_{i_2}^2\}$  并且  $t+1$  时刻第  $c$  条链处于状态  $S_j^c$  的联合概率;  $\gamma_i^c(j, m)$  为在给定模型参数  $\lambda$  和观测值序列  $O$  的条件下,  $t$  时刻第  $c$  条链处于状态  $S_j^c$  并且对应该状态的第  $m$  个高斯分布的联合概率。式 (14) ~ (18) 为更新模型参数公式。

### 3 CHMM 的输电线路状态评估流程

基于 CHMM 的架空输电线路状态评估, 主要分为两部分: 离线训练与在线诊断。

离线训练, 就是通过设备在正常、注意、异常、严重四个状态下的历史统计数据, 对 CHMM 的模型参数进行训练, 其具体步骤为:

(1) 参数初始化: 根据实际应用情况选择合适的状态数目  $\{N_c\}$ 、高斯分量数目  $\{M_c^c\}$ ; 选择合适的初

始参数  $\lambda = (\boldsymbol{\pi}, \boldsymbol{A}, \boldsymbol{B})$ , 即  $\{N_i^c\}$ ,  $\{a_{i,j}^c\}$ 、 $\{w_{j,m}^c\}$ 、 $\{\boldsymbol{\mu}_{j,m}^c\}$  和  $\{\boldsymbol{\Sigma}_{j,m}^c\}$ 。这里仅考虑“正常”、“注意”、“异常”和“严重”四种状态,所以状态数目  $N_c = 4$ , 高斯分量数目  $\{M_j^c\}$  可以设为  $M_j^c = 5$ 。

(2) 根据式(8)~(11)递推计算前向变量  $\partial_i(t)$  和后向变量  $\beta_i(t)$ , 然后再根据式(12)、(13)计算对应的后验概率  $\xi_i^c(i, j)$  和  $\gamma_i^c(j, m)$ 。

(3) 由于步骤(2)得到的前向变量、后向变量和后验概率都是基于步骤(1)的初始化参数, 而初始化参数  $\lambda = (\boldsymbol{\pi}, \boldsymbol{A}, \boldsymbol{B})$  是一种理想化设定值, 并不能完全契合真值, 因此还需要对其进行参数重估, 不断优化直到接近真实值。根据式(14)~(18)更新模型参数, 并通

过设定的阈值控制其精度, 经过多次重估, 当参数值能够满足设定的阈值, 则此时的模型参数  $\bar{\lambda} = (\bar{\boldsymbol{\pi}}, \bar{\boldsymbol{A}}, \bar{\boldsymbol{B}})$  就是最终值。

在线诊断, 就是将实际数据或测试数据带入训练好的 CHMM 当中, 计算概率值  $P(O | \bar{\lambda}_i)$ 。其中  $\bar{\lambda}_i = \bar{\lambda}_1, \bar{\lambda}_2, \bar{\lambda}_3, \bar{\lambda}_4$  分别代表“正常”、“注意”、“异常”和“严重”四种状态训练得到的模型参数值。通过计算, 找出使概率值最大的那个参数, 其对应的状态组别就是该测试数据实际所处的状态<sup>[17-19]</sup>。

图1 为基于 CHMM 的诊断流程图。

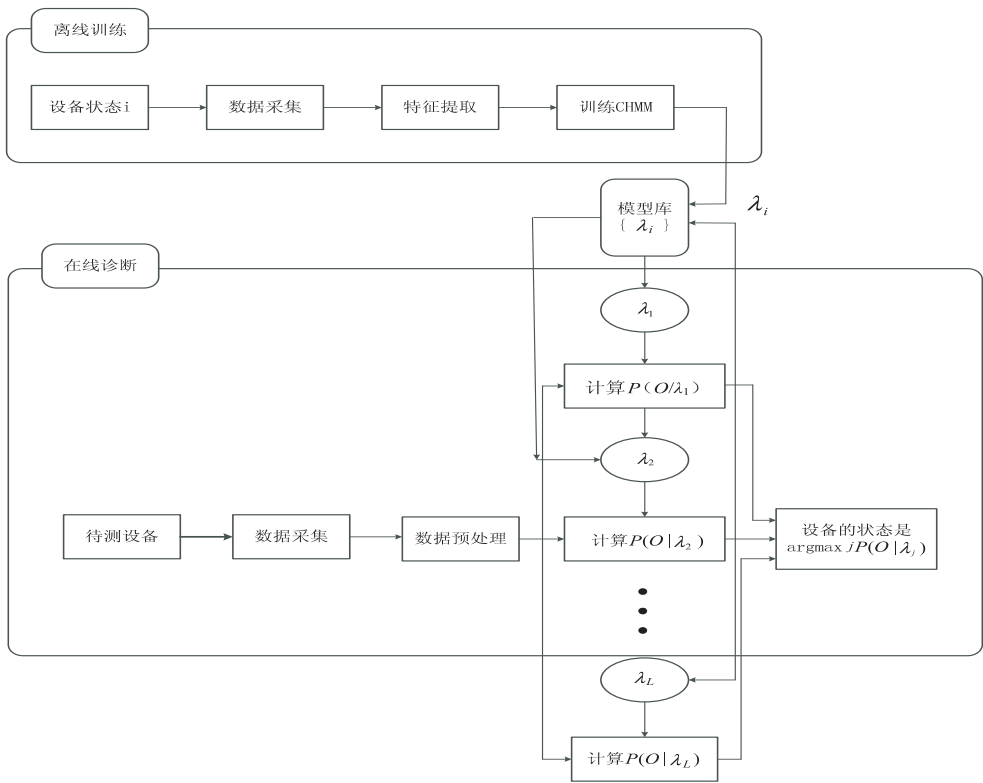


图1 基于 CHMM 的诊断流程图

4 算例分析

以一条 110 kV 架空输电线路为例, 对其进行状态评估。为方便比较与计算, 仅考虑导线弧垂和导线温度两个检测指标。通过查询历史统计数据, 收集该条架空输电线路的导线弧垂和导线温度历史统计数据。

通过统计数据对 CHMM 进行模型训练, 并按上述内容分别求得四种状态下 CHMM 的模型参数  $\lambda_1, \lambda_2, \lambda_3$  和  $\lambda_4$ 。对架空输电线路进行状态评估, 即找出使  $P(O/\lambda_i)$  最大的参数  $\lambda_i$  所对应的状态。

为了验证 CHMM 的有效性, 将提出的 CHMM 与传统的 HMM 评估方法进行对比。同时为了方便描述, 将导线弧垂数据称为数据通道 1, 导线温度数据称为

数据通道 2。同时根据历史统计数据生成“正常”、“注意”、“异常”、“严重”状态下的测试数据各十组, 代入已训练好的 CHMM 和 HMM 当中, 计算得到最终概率值  $P(O/\lambda)$  的最大对数似然概率值  $\ln^{P(O/\lambda)}$ , 如图 2~5 所示。

由图可知, 采用 HMM 分别对通道 1 的导线弧垂数据和通道 2 的导线温度数据进行状态评估, 虽然也能够评估出线路的状态为“正常”, 但是, 通道 1“正常”状态曲线与“注意”状态曲线有一个测试结果出现重叠; 通道 2“正常”状态曲线与“注意”状态曲线有两个测试结果出现重叠, 并且可以直观看出, “正常”状态与“注意”状态的曲线较为接近, 存在区分度不高的现象。同理, 在对“注意”、“异常”、“严重”状态的十组

测试数据进行评估时,也出现了类似的重叠现象,而通过 CHMM 对双通道数据进行耦合评估的结果,不但没有出现测试结果重叠的现象,而且各状态评估结果曲

线都有较好的区分度,这表明 CHMM 相比于传统的 HMM 具有更高的精确度与区分度。

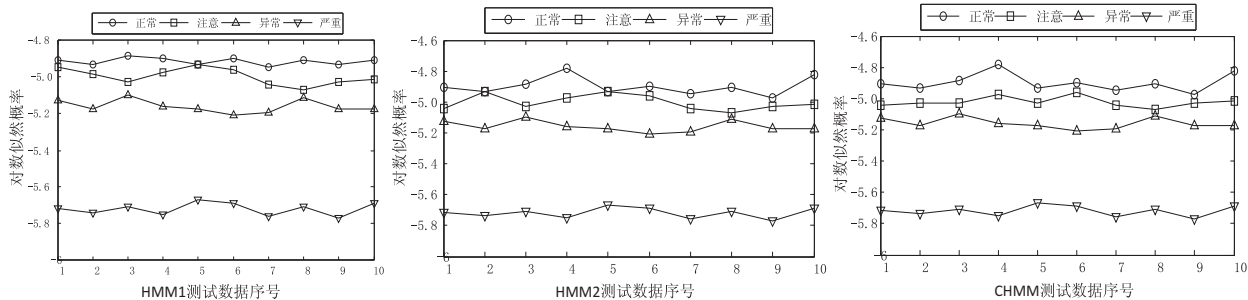


图 2 “正常”状态测试数据评估结果

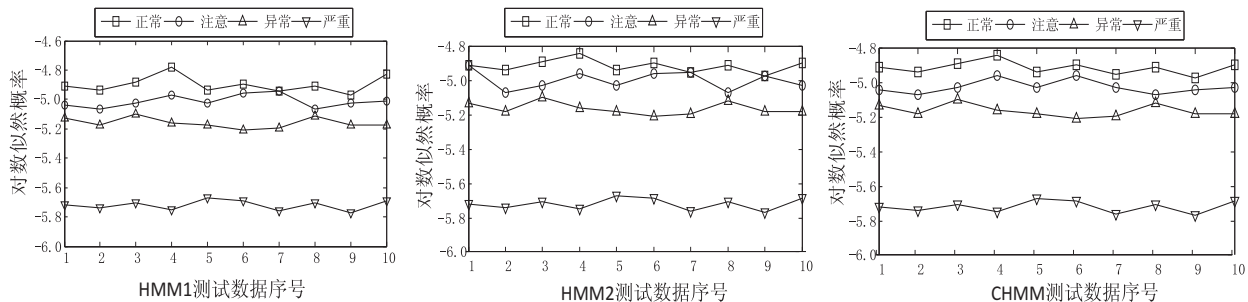


图 3 “注意”状态测试数据评估结果

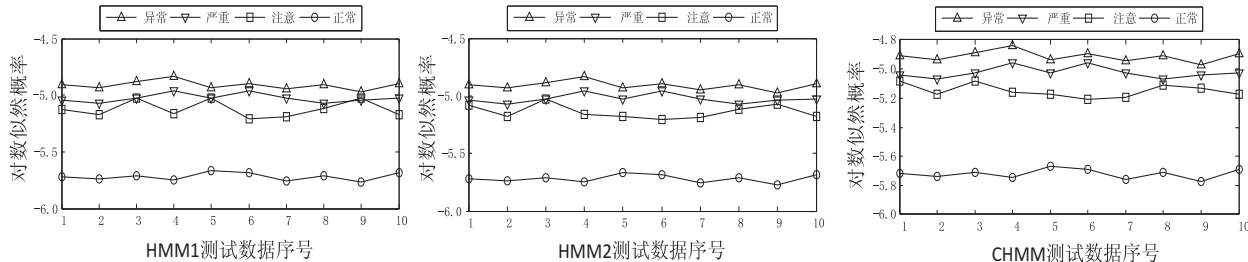


图 4 “异常”状态测试数据评估结果

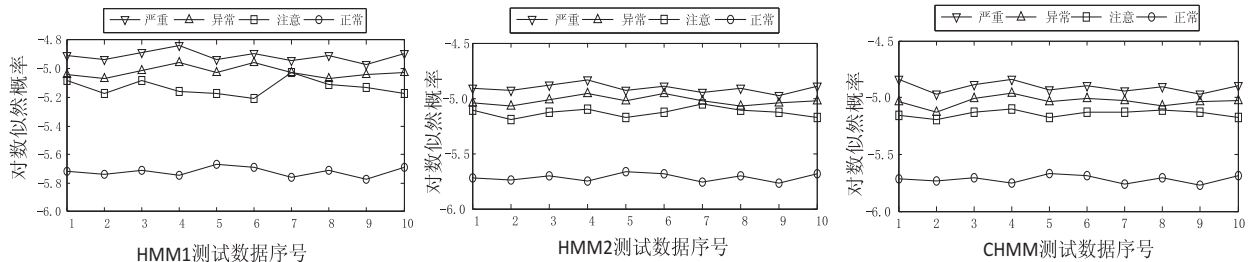


图 5 “严重”状态测试数据评估结果

## 5 结束语

为对架空输电线路进行准确的状态监控和评估,提出了一种基于人工智能的机器学习方法,即应用耦合隐马尔可夫模型对架空输电线路进行状态评估。根据评估要求收集架空输电线路在正常、异常、注意、严重四种状态下的历史评估数据并将数据进行归一化处理。利用耦合隐马尔可夫算法对归一化后的四类数据进行模型训练,得到四组不同状态下的模型参数,建立起四个状态的耦合隐马尔可夫模型。将归一化后的测

试数据带入建立好的四组模型当中,得到四个状态评估值,其中评估值最大的该组模型所对应的状态组别就是测试数据所反映的线路状态。实例分析验证结果表明,该方法能有效地融合各通道数据,并且比传统的 HMM 精确度更高。

## 参考文献:

- [1] 郭永基. 电力系统可靠性分析[M]. 北京:清华大学出版社,2003.
- [2] 赵 渊,谢开贵. 电网概率风险评估中元件可靠性参数的

不确定性分析[J]. 电力系统自动化,2011,35(4):6-11.

[3] 孙元章,刘海涛,程林,等. 运行可靠性在线短期评估方案[J]. 电力系统自动化,2008,32(3):4-8.

[4] 汲国强,张伯明,吴文传,等. 一种适用于可靠性评估的电网设备时变停运模型[J]. 中国电机工程学报,2013,33(1):56-62.

[5] 吴文传,宁辽逸,张伯明,等. 一种考虑二次设备模型的在线静态运行风险评估方法[J]. 电力系统自动化,2008,32(7):1-5.

[6] 宁辽逸,吴文传,张伯明. 电力系统运行风险评估中元件时变停运模型分析[J]. 电力系统自动化,2009(16):7-12.

[7] 冯永青,吴文传,孙宏斌,等. 现代能量控制中心的运行风险评估研究初探[J]. 中国电机工程学报,2005,25(13):73-79.

[8] 汲国强,吴文传,张伯明,等. 一种适用于状态检修的电力设备时变停运模型[J]. 中国电机工程学报,2013,33(25):139-146.

[9] 张京京,荀鹏,冯健飞,等. 智能电网安全与自主可控的分析与评测[J]. 计算机技术与发展,2016,26(5):79-85.

[10] 韩富春,董邦洲,贾雷亮,等. 基于贝叶斯网络的架空输电线路运行状态评估[J]. 电力系统及其自动化学报,2008,20(1):101-104.

[11] 王巍. 基于云参数贝叶斯网络的威胁评估方法[J]. 计算机技术与发展,2016,26(6):106-110.

[12] Bengio Y, Frasconi P. Input-output HMMs for sequence processing[J]. IEEE Transactions on Neural Networks, 1996, 7(5):1231-1249.

[13] Chen C, Liang J, Zhao H, et al. Factorial HMM and parallel

HMM for gait recognition[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 2009, 39(1):114-123.

[14] Liu C D, Chung Y N, Chung P C J. An interaction-embedded HMM framework for human behavior understanding; with nursing environments as examples[J]. IEEE Transactions on Information Technology in Biomedicine, 2010, 14(5):1236-1246.

[15] 郑晴晴,傅攀,李威霖. CHMM在滚动轴承故障诊断中的应用研究[J]. 现代制造工程,2013(12):111-115.

[16] 何永秀. 电力综合评价方法及应用[M]. 北京:中国电力出版社,2011.

[17] 张凯,齐丽娜. 基于连续隐马尔可夫模型的协作频谱检测[J]. 计算机技术与发展,2015,25(6):64-68.

[18] 刘江华,陈佳品,程君实. 基于光流及耦合隐马尔可夫模型的动态手势识别[J]. 上海交通大学学报,2003,37(5):720-723.

[19] 李伟伟,张涛,马媛媛,等. 基于中间件的多源数据交换系统[J]. 计算机技术与发展,2016,26(5):95-98.

[20] 段群,吴粉侠,李红. 双通道分块同态滤波彩色图像增强算法[J]. 计算机技术与发展,2016,26(1):82-85.

[21] 肖文斌,陈进,周宇. 耦合隐马尔可夫模型在轴承故障诊断中的应用[J]. 噪声与振动控制,2011,31(6):161-164.

[22] 林国余,柏云,张为公. 基于耦合隐马尔可夫模型的异常交互行为识别[J]. 东南大学学报:自然科学版,2013,43(6):1217-1221.

(上接第163页)

三维目标过多时计算机特别是国产计算机卡顿明显等。后续工作将继续对这些问题展开研究,实现国产平台上的自主可控三维态势引擎。

参考文献:

[1] Brant W. Mental imagery and creativity: cognition, observation and realization[M]. Germany: Springer, 2013: 227-228.

[2] Hujsak R, Woodburn J W, Seago J H. The Orbit Determination Tool Kit (ODTK)-Version 5[J]. Advances in the Astronautical Sciences, 2007, 127: 381-400.

[3] 蒲玮,李雄,吴成海. 三维战场态势显示标绘技术[J]. 科技导报,2014,32(34):62-68.

[4] 吕庆,孟剑萍. 基于场景图形管理技术的三维空中态势引擎设计与实现[J]. 指挥控制与仿真,2011,33(6):58-64.

[5] OpenSceneGraph reference manual V. 2. 2[M]. [s. l.]: [s. n.], 2007: 36-43.

[6] Hagedorn J. High performance visualization[M]//Mathematical and computational sciences division. [s. l.]: [s. n.],

2007: 56-71.

[7] 王琪. 网络二维地图与三维虚拟场景集成探讨[J]. 测绘科学, 2008, 33(2): 124-126.

[8] 吴晓雪,任鸿翔,张显库,等. 基于osgEarth三维数字地球建设的研究[J]. 大众科技, 2015(1): 1-3.

[9] 王宝山,武继军,罗建元. 大地坐标转换模型与精度研究[J]. 河南理工大学学报: 自然科学版, 2006, 25(2): 111-115.

[10] 吴运金,赵玉国,张甘霖. 基于SRTM数据的中国1:100万SOTER地形体的构建[J]. 土壤, 2010, 42(1): 123-130.

[11] 徐智勇,吴小芳. LOD技术在电子地图显示中的应用研究[J]. 测绘信息与工程, 2004, 29(5): 19-21.

[12] 韩桂明,韩传久,莫建文,等. 基于OSG的雷达三维雷达信息显示系统仿真[J]. 微计算机信息, 2008, 24(13): 247-249.

[13] 韩晓宁,陈希,王娇艳. 三维海战场雷达探测可视化研究与实现[J]. 计算机科学, 2013, 40(3): 147-150.

[14] 刘立辉,孟庆鑫. 基于动态链接库的复杂信息系统分层框架设计[J]. 计算机与信息技术, 2009(5): 39-41.