

基于贝叶斯神经网络的智能诊断系统

张宗辉

(中国海洋大学 管理学院, 山东 青岛 266100)

摘要:模型复杂度是制约智能诊断系统的瓶颈,利用贝叶斯网络为扩展神经网络提供了新的思路。融入模型的先验知识,与观察到的数据样本相结合,来进行后验概率的贝叶斯推理。使用马尔科夫链蒙特卡罗方法以获得模型参数的后验分布,实现了对神经网络模型中不同部分复杂度的近制,并在实验中得到证实。

关键词:贝叶斯网络;智能诊断;马尔科夫链蒙特卡罗模拟;神经网络

中图分类号:N93 **文献标志码:**A **文章编号:**1671-1807(2011)07-0114-04

神经网络与模糊逻辑系统具有很强的互补性,是目前基于计算智能两种常用的智能诊断方法。近年来,随着神经网络与模糊理论研究的进一步深入,由这两种计算智能融合而成的模糊神经网络得到人们的高度重视。在故障诊断领域,基于模糊神经网络的诊断方法代表了一种富有生命力的方向。

基于神经网络和模糊逻辑的智能诊断系统如何进行模型复杂度控制是近年来的研究热点。贝叶斯网络为进行神经网络复杂度提供了新的思路,使用马尔科夫链蒙特卡罗法来近似后验推理公式中复杂积分,并在实验中得到证实。

1 智能诊断系统

1.1 综述智能诊断系统

故障智能诊断系统,它是目前刚刚发展起来、并初步显示其成就的故障诊断系统。人工智能技术的发展,特别是专家系统在故障诊断领域中的应用,为设备故障诊断的智能化提供了可能性,也使故障诊断技术进入了新的发展阶段。它实际上是由原来的以数值计算和信号处理为核心的诊断过程向以知识处理和知识推理为核心的诊断过程的飞跃。智能故障诊断是当前诊断技术的发展方向,人们对基于知识的诊断技术和诊断系统进行了深入的研究。

智能诊断系统将神经网络和模糊逻辑整合在一起,使得神经网络和模糊逻辑发挥它们的特点,为诊断提供新的途径。神经网络在处理非线性数据方面已经表现出其他模型所没有的能力。诊断系统所面对的对象并不是像其它应用型系统当中有明确定义

的数据对象,例如,在医疗诊断系统当中,对于病人精神状况的描述,通常是精神良好或是精神不振这类笼统的描述。这个时候,模糊逻辑对于这种对象就会发挥卓越的作用,模糊逻辑在智能诊断系统当中成为其成功的关键因素。

1.2 Neural Network 神经网络

神经网络(Neural Network)具有很强的并行处理和自组织学习能力,特别适合在非线性、多维等复杂领域,目前已应用于模式识别、分类预测、智能模拟系统等领域。它是在现代神经生物学研究成果的基础上发展起来的一种模拟人脑信息处理机制的网络系统,它不但具有处理数值数据的一般计算能力,而且还具有处理知识的思维、学习、记忆能力。^[1]

目前应用比较广泛的神经网络主要包括:BP 神经网络、RBF 网络、自组织网络、Hopfield 网络。BP 神经网络是最常见也是应用最多的神经网络。BP 神经网络属于多层前馈神经网络,主要包含输入层、输出层和若干隐层。前一层和后一层通过权系数连接。隐层的变换函数一般为非线性函数,如 S 型函数,这样可以保证输出量是 0~1 之间的连续值,从而可以实现从输入到输出的非线性变换。BP 算法的基本思想是:学习过程包括信号的正向传播和误差的反向传播两个过程。信号正向传播时,输入样本从输入层传入,经各隐层逐层传递,最终到达输出层。若输出层的实际输出与期望输出之间的误差小于预先设定的阈值,则传递结束,否则将转入误差的反向传播阶段^[2]。误差反传是将实际输出与期望输出之间的

收稿日期:2011-04-07

作者简介:张宗辉(1985—),男,山东青岛人,中国海洋大学管理学院,管理科学与工程硕士研究生,研究方向:智能决策支持系统与工业集成工程。

误差以某种形式通过隐层逐层向前传递,并将误差分摊给各层的所有神经单元,从而获得各层单元的误差信号,此误差信号就作为修正各单元权值的依据。这两个过程将一直进行下去,直到实际输出和期望输出之间的误差小于预先设定的阈值,或者达到最大训练次数。权值不断调整的过程,也就是网络的学习过程。




图 1 神经网络示意图

1.3 Fuzzy logic 模糊逻辑

L. A. Zadeh 在 1965 年提出了模糊集的概念^[5],模糊集是一种边界不分明的集合,模糊集与普通集合既有区别又有联系。对于普通集合而言,任何一个集要么属于该集合,要么不属于该集合,其间有明确的边界。对于模糊集合,一个元素可以既属于该集合又不属于该集合,其边界是模糊的。模糊系统是建立在自然语言的基础上,自然语言中常采用一些模糊的概念,如“天气晴朗,中等年纪”等。如何描述这些模糊概念,并对它们进行分析、推理,这正是模糊集合与模糊逻辑所要解决的问题。




图 2 模糊逻辑诊断系统

所谓语义变量(Linguistic Variable)是以人们自然语言中的词语为值来表示对某种事物的感知程度,而不是以数值形式来传达感知程度。例如,可以用词组:{非常重要、不重要、普通、重要、非常重要}来表示评估者对好坏的感受程度。

模糊集使某元素以一定程度属于某集合,某元素属于某集合的程度由“0”与“1”之间的一个数值——隶属度来描述。把一个具体的元素映射到一个合适的隶属度是由隶属函数来实现的,隶属函数可以是任意形状的曲线,隶属函数的值域为 $[0,1]$,常用的隶属

函数 $\mu_A(x)$ 有:高斯型隶属函数、Sigmoid 型隶属函数、梯形型隶属函数、三角型隶属函数^[3]。

模糊化方法有两种基本类型:离散法和连续法。在离散的模糊化方法中,首先对精确量进行离散化处理,然后针对所考虑的模糊集合确定每一个离散值所对应的隶属度,模糊化的结果很适合用表格来表示。连续的模糊化方法则致力于确定隶属函数的具体函数表达式。一旦确定了 $\mu_A(x)$,则对于连续变化的精确量 x ,相应的隶属度也将呈现连续变化的特性^[4]。应予说明的是,离散的模糊化方法实际上也需要通过相应的隶属函数来确定每个离散值所对应的隶属度,只是其处理仅针对离散点进行。一般来说,离散法计算量较小,而连续法对模糊信息的利用更为充分。

去模糊化的作用则在将基于模糊逻辑推理的故障智能诊断系统产生的模糊量(故障输出)转换成一个精确量。本系统使用了 Chen 提出的最大最小集合法。该方法计算不复杂,目前的应用范围很广。最大最小集合法主要是应用 Fuzzy Max 和 Fuzzy Min 与模糊数的交点,以决定左右偏好值,再利用左右偏好值以求出总偏好值,此值即为代表模糊数的单一明确值。其中,Fuzzy Max 和 Fuzzy Min 是分别表示模糊最大集和模糊最小集的模糊数。

模糊规则库是模糊逻辑系统的核心部分,它一般是由一组模糊推理规则组成的。它的一般形式为:

$$R^{[k]}: \text{if } x_1 \text{ is } A_1^k \text{ and } \cdots \text{ and } x_n \text{ is } A_n^k \text{ then } y \text{ is } B^k$$

式中: $R^{(k)}$ 表示第 k 条规则。

模糊推理机是基于模糊逻辑推理的故障智能诊断系统工作方式即该系统逻辑推理所采用的推理原理,它的作用是根据故障征兆的输入情况,结合系统的模糊规则库的有关规则条,运用该系统采用的某种推理机进行逻辑推理,最后输出诊断结果,即故障的原因。

1.4 系统模型

模糊逻辑推理通过分析系统输入,将输入状态与模糊规则库进行匹配,寻找适当的推理规则。接着相应的状态以及 IF-THEN 推理规则进入模糊推理机,进行自动处理。随后结果将被进行去模糊化操作。系统根据去模糊化操作所得到的结果进行相行的修复操作。

神经网络在系统开始时依据设置进行一系列的初始化动作,使得第一次进入系统的数据能够得到合理的处理。随后,神经网络会进行相应的结构调

整,并将结果反映给模糊逻辑推理。




图 3 智能诊断模型

2 贝叶斯网络控制系统模型复杂性

2.1 上述模型缺陷及现有解决方法

神经网络由于其特有的特点,成为人工智能,尤其是非确定性人工智能(Uncertainty in Artificial Intelligence, UAI)研究的热点。其在非线性数据处理方面独特的能力,使得神经网络取得卓越的成绩。但复杂度控制成为制约神经网络发展的重要因素。为了充分发挥神经网络在泛化能方面的优势,控制神经网络的复杂度成为当前神经网络研究方面最迫切的问题。

在已有的控制神经网络复杂度方法中,如权衰减等,大多都是依据对神经网络实验的经验性理解基础上做出一些相对应的调整。因此对于那些对神经网络的实验设计没有经验的研究来说,控制神经网络复杂度成为一个非常困难的事情。

贝叶斯网络为控制神经网络的复杂度提供了一个新的思路。在贝叶斯分析框架下,将模型参数视为不确定性量,使用显式的概率分布假设进入到模型中加以分析和推断。由于神经网络的模型复杂度在贝叶斯框架中可以很自然地加以显式表达和控制,我们可以通过定义一些超参数 α 的模糊先验来控制模型参数复杂性的未知程度,进一步通过对模型参数的分组,及在各权组上使用不同的公共超参数,允许模型在不同的部分具有不同的复杂度。预测值就是所有被采样的模型复杂度的加权平均,该权系数由各模型对给定数据的后验概率来确定。

2.2 贝叶斯神经网络

考虑诊断系统中的分类问题,对于有 K 个目标分类,第 i 个输入 I_i 是 m 维的特征向量, O_i 是对应的期望输出向量。假定系统存在噪声,服从高斯分布 $N(0, \sigma^2)$ 。则给定数据集 D 和神经网络权值矩阵 W ,其参数为

$$P(y|x, D) = \int P(y|x, W) p(W|D) dW$$

$$E(W) = -\ln P(D|W)$$

令 $P(W)$ 为在获得任何训练数据之前对网络权值参数 W 的先验分布,定义一个正则化项为

$$E(W) = -\ln P(D|W)$$

应用贝叶斯公式得:

$$\ln P(W|D) = \ln P(D|W) + \ln P(W) + \text{const} \\ = -E(W) + \text{const}$$

其中:const 为常数。可定义贝叶斯神经网络的总误差函数为:

$$U(W) = E(W) + R(W)$$

由上式可得:

$$P(W|D) = (1/Z) \exp(-U(W))$$

其中 Z 是一个归一化常数。将上式代入第一个公式,得:

$$P(y|x, D) = \int P(y|x, w) \frac{1}{Z} \exp(-U(W)) dW$$

由此,网络参数预测就变为对上式的计算,但该公式不能进行直接求解,就要求我们做一些数值近似。我们采用了马尔科夫链蒙特卡洛法(MCMC)。假定马尔科夫链满足遍历性,由该链上的采样所能达到的稳定分布我们就认为可以代替上式的后验概率会布。用所到的马尔科夫链上的样本序列 $\{W_t\}$,进行近似计算式为

$$P(y|x, D) = \frac{1}{n_5 - n_0 + 1} \sum_{t=n_0+1}^{n_0+n_5} P(y|x, W_t)$$

其中, n_0 为被舍弃的初始马尔科夫链; n_5 为来自平衡后验分布的向量样本数。

2.3 MCMC 马尔科夫链蒙特卡洛方法

MCMC 方法的基本思想是构造一条具有指定平稳分布 $\pi(\theta|X)$ 的马尔可夫链,即它的转移分布收敛到指定的后验分布。然后充分长地运行此马尔科夫链,当链上取值的分布与其平稳分布足够接近时,把来自链上的样本作为来自 $\pi(\theta|X)$ 的样本,基于这些样本进行各种统计推断。例如求均值、方差等。不同的 MCMC 方法主要是构造 Markov 链的方法不同,常用的构造马尔科夫链的方法有 Metropolis-Hasting 算法和 Gibbs 算法。

使用 Metropolis-Hasting 构造马尔科夫链的过程通常是产生一个样本 $\{W_1, W_2, \dots, W_n\}$ 链,而成员是来自与条件概率 $P(W|\alpha, D)$ 成直接比例的采样, n 就是链长($n = n_0 + n_s$)。设给定了迭代步 t 的当前状态 W_t , 从一个关于 W_t 的对称分布中获得一个新的候选状态 $\tilde{W}$, 若 $U(\tilde{W}) < U(W_t)$, 则接受该候选状态为新的状态, 否则, 仅以概率 $P(W_{t+1} = \tilde{W} | W_t) = \exp[U(W_t) - U(\tilde{W})]$ 来接受。结果由选择的一系列 $\{W_t\}$ 样本组成了一个马尔可夫链。Metropolis-Hasting 算法的缺点是以缓慢的随机行走方式进行

$\{W_i\}$ 空间的探索,连续的采样过程存在高度的相关性,这样使得达到平衡分布的时间相当长。为了克服这个困难,我们采用了混合蒙特卡洛(Hybrid Monte Carlo)来加速收敛过程。它综合了 Metropolis—Hastings 算法与一个动力系统的模拟,利用了梯度信息而避免随机行走。从后验分布 $P(W, \alpha | D) = P(\alpha | D)P(W | \alpha, D)$ 采样遵循二步法,第一步固定超参数 α ,用混合蒙特卡洛法来对网络权值的后验分布进行采样;第二步改变超参数 α ,从后验分布 $P(\alpha | W, D)$ 中获得一个样本,这个二步法过程就执行了一个吉布斯(Gibbs)采样。

3 实验

本实验 MCMC 模拟都是先在准平衡阶段运行 50~100 个迭代步,接着进行 400~800 个迭代步较

长时间的采样阶段,取最后 200 个迭代步 $n_s = 200$ 上的样本作为最终预测式的模型。为了控制模型不同部分的复杂度,将模型参数分为 4 个权组,分别为输入—隐层、隐层单元阈值、隐层—输出层、输出层单元阈值。每个权组服从均值为 0、精度为 a_g ($g = 1, \dots, 4$)的高斯分布,而超参数 α 由一个模糊 Gamma 先验分布控制,取该模糊先验分布的形状参数 $\alpha_0 = 0.5$,均值 $v = 0.05$ 。

我们将此系统应用于模拟智能入侵检测中,实验显试,应用了智能诊断系统之后,系统入侵数量随时间大量减少。例如,在时间 30—40,系统首先学习相应的数据,进行神经网络权值初始化,在 45 这个时间片,入侵开始明显减少,因为系统对入侵规律有了认识,进行了相应的拦截。




图 4 实验结果

4 结论

利用网络模型参数的先验知识和相应的样本数据信息,应用贝叶斯分析和马尔可夫链蒙特卡罗模拟,得到网络参数的后验分布,并对后验分布进行预测。将网络模型复杂度的不确定性以超参数变量的形式和显示的概率分布加入到贝叶斯模型中,并且,根据实测样本数据的特性加以自动地调整来控制模型参数,从而达到控制模型复杂度的效果。

参考文献

[1] LAMPINEN JOUKO, VEHTARI AKI. Bayesian approach

for neural networks[J]. Review and case studies. Neural Networks, 2001, 14(3): 257—274.

[2] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators[J]. Neural Computing, 1990(2) : 210—215.

[3] BISHOP C M. Neural Networks for pattern recognition[M]. New York: Oxford University Press, 1995.

[4] GUPTA M M, RAO D H. On the principles of fuzzy neural networks. [J]. Fuzzy Sets and Systems, 1994, 68(1) : 1—8.

[5] CHEN S H. Ranking, Fuzzy Numbers with Maximizing set and minimizing set. [J]. Fuzzy Sets and Systems, 1985, 1 (17): 113—129.

Intelligence Diagnosis System Based on Bayesian Neural Network

ZHANG Zong-hui

(School of Management, Ocean University of China, Qingdao Shandong 266100, China)

Abstract: Controlling the complexity of model is bottleneck of intelligence diagnosis system. Bayesian Networks provide a new approach for extending Neural Network. Prior know ledge about the model can be corporate with training data to implement Bayesian inference. Markov chain Monte Carlo will help to gain predict distribution in order to control complexity of different parts of model which had been proved in experiment.

Key words: bayesian networks; intelligence diagnosis; Markov Chain Monte Karlo; neural network