

基于深度置信网络的卡尔曼滤波算法改进

郭继峰 李忠志* 张国强 房德智 李艳娟
(东北林业大学信息与计算机工程学院 黑龙江 哈尔滨 150040)

摘要 卡尔曼滤波是一种应用广泛的基于最小方差的递推式滤波算法,根据一定滤波规则对系统的状态进行估计。采用某种统计量最优方法对噪声和系统模型统计特性的先验知识决定的滤波的性能和估计的准确性进行度量。不精确的先验知识将导致滤波性能的明显下降和发散。采用新息自适应卡尔曼滤波克服标准卡尔曼滤波需要在先验条件下进行估计的缺点,通过深度置信网络对噪声的协方差矩阵做出调整,从而提高滤波性能。

关键词 卡尔曼滤波 新息 深度置信网络 电磁继电器 寿命预测

中图分类号 TP3 **文献标识码** A **DOI**:10.3969/j.issn.1000-386x.2019.06.045

IMPROVEMENT OF KALMAN FILTER ALGORITHM BASED ON DEEP BELIEF NETWORK

Guo Jifeng Li Zhongzhi* Zhang Guoqiang Fang Dezhi Li Yanjuan

(Institute of Information and Computer Engineering, Northeast Forestry University, Harbin 150040, Heilongjiang, China)

Abstract Kalman filtering is a widely used recursive filtering algorithm based on minimum variance, which estimates the state of the system according to certain filtering rules. We used a statistical optimum method to measure the filtering performance and estimation accuracy determined by prior knowledge of the statistical characteristics of noise and system models. The inaccurate prior knowledge could lead to a significant drop and divergence of the filtering performance. The innovation adaptive Kalman filtering overcame the disadvantage of the standard Kalman filtering that needed to be estimated under prior conditions. The covariance matrix of noise was adjusted by the deep belief network to improve the filtering performance.

Keywords Kalman filter Innovation Deep belief network Electromagnetic relay Life prediction

0 引言

卡尔曼滤波是一种基于最小方差下的最优估计方法。在系统模型、过程噪声和测量噪声的统计特性都已知的条件下,输入观测量、输出估计值,并且观测更新与时间变化具有一定联系,通过这一联系卡尔曼滤波可以不断地进行递推和对估计进行修正,主要解决的是随机线性问题^[1]。卡尔曼滤波解决的是对线性系统的估计,主要算法设计如下,其中 $X(k+1)$ 为 $k+1$ 时刻目标状态变量, $f(k)$ 为状态转移矩阵, $G(k)$ 为噪声驱动矩阵, $Z(k+1)$ 为 $k+1$ 时刻观测向量, $H(k)$ 为

观测矩阵, $R(k)$ 为 k 时刻噪声协方差矩阵。

(1) 状态估计的一步预测方程:

$$\hat{X}(k+1|k) = f(k)\hat{X}(k|k) \quad (1)$$

(2) 一步预测状态的协方差为:

$$P(k+1|k) = f(k)P(k|k)f'(k) + G(k)Q(k)G'(k) \quad (2)$$

(3) 一步观测矩阵的协方差为:

$$\hat{Z}(k+1|k) = H(k+1)\hat{X}(k+1|k) \quad (3)$$

(4) 观测向量的预测误差协方差为:

$$S(k+1) = H(k+1)P(k+1|k)H'(k+1) + R(k+1) \quad (4)$$

(5) 新息或测量残差为:

$$v(k+1) = Z(k+1) - \hat{Z}(k+1 | k) = Z(k+1) - H(k+1)\hat{X}(k+1 | k) \quad (5)$$

(6) 滤波器增益为:

$$K(k+1) = P(k+1 | k)H'(k+1)S^{-1}(k+1) \quad (6)$$

(7) 卡尔曼滤波算法的状态更新方程为:

$$\hat{X}(k+1 | k+1) = \hat{X}(k+1 | k) + K(k+1)v(k+1) \quad (7)$$

(8) 滤波误差协方差的更新方程为:

$$P(k+1 | k+1) = P(k+1 | k) - K(k+1)S(k+1)K'(k+1) = [I - K(k+1)H(k+1)]P(k+1 | k) \quad (8)$$

通过不断重复以上步骤来不断更新滤波的误差协方差矩阵,获得更精确的滤波效果,卡尔曼滤波算法的结构如图 1 所示。




图 1 卡尔曼滤波结构框图

1 标准卡尔曼算法在滤波存在的问题分析改进

传统的卡尔曼滤波算法主要有自适应卡尔曼算法^[15]、模糊卡尔曼算法^[16]和新息卡尔曼算法等。其中韩亚坤等^[17]提出的新息自适应卡尔曼滤波算法没有考虑对新息测量噪声协方差矩阵进行在线优化,李忠良^[18]提出基于 BP 神经网络的自适应卡尔曼滤波算法没有考虑对神经网络进行优化,只使用简单的三角函数来对比试验,忽略了其他影响卡尔曼滤波的因素,对预测精度有一定的影响。针对以上卡尔曼算法在滤波中出现的,当系统模型不精确时滤波精度不高的问题,提出一种基于深度置信网络模型的新息卡尔曼滤波算法。首先通过对新息卡尔曼滤波算法在滤波过程中利用实时观测量和估计量信息在线修正参数和噪声的统计特性,然后使用深度置信网络模型在线调整噪声协方差矩阵 Q ,使其接近实际噪声量,从而提高滤波估计精度^[2]。

1.1 新息自适应卡尔曼滤波原理

自适应卡尔曼滤波算法是为了解决理想状态下的噪声无法在现实环境中实现这个问题而提出的一种改进卡尔曼算法,而新息自适应卡尔曼算法是其中的一种。通过式(3)和式(8)推导出 k 时刻的新息,其中 $I(k)$ 为 k 时刻的新息, C 为新息协方差, $Q(k+1)$ 为 $k+1$ 时刻噪声矩阵, $R(k)$ 为 k 时刻观测噪声协方差矩阵:

$$I(k) = Y(k) - H(k)\bar{X}(k) \quad (9)$$

k 时刻的新息协方差:

$$C(k) = H(k)P(k)H(k) + R(k) \quad (10)$$

由式(4)和式(7)得到 $Q(k+1)$ 的表达式:

$$Q(k+1) = K(k)H(k)P(k) \quad (11)$$

最后将式(11)代入式(6)得出:

$$Q(k+1) = K(k)C(k)H(k)K'(k) \quad (12)$$

由式(10)变换可得到新息测量噪声协方差矩阵 R :

$$R(k) = C(k) - H(k)P(k)H'(k) \quad (13)$$

通过以上的推导和变换就可将标准的卡尔曼滤波算法改写成基于新息的自适应滤波表达式,新息的自适应卡尔曼滤波和标准的卡尔曼滤波的不同在于,新息自适应卡尔曼滤波表达式中的噪声协方差不再是固定的,而是对噪声进行实时估计,从而使 R 和 Q 更加精确,提高了滤波的精度。

1.2 深度置信网络模型构建与原理

深度置信网络(Deep Belief Network)^[14]由许多层用于接受输入的显层神经元(以下简称显元)和用于提取特征的隐层神经元(以下简称隐元)构成,因此隐元也可以被称为特征检测器^[3]。顶部两层之间是无方向连接的,并构成联合记忆。下层的其他上层和下层之间存在有方向连接。最底层表示的是数据向量,每个神经元表示为一维数据向量。受限玻尔兹曼机 RBM(Restricted Boltzmann Machine)是 DBN 的主要组成元件。因此, DBN 的训练过程是渐进的。在每一层中,数据向量用于推断隐藏层神经元,并且该隐藏层被视为下一层的数据向量。其结构如图 2 所示。




图 2 模型结构图

1.2.1 受限玻尔兹曼机结构及工作原理

受限玻尔兹曼机是由一层显性神经元和一层隐性神经元组成的,并且两层神经元之间为双向全连接,所以又被成为神经感知器,结构如图 3 所示。




图 3 受限玻尔兹曼机网络结构图

在受限玻尔兹曼机中,任意两个连接的隐层神经元和显层神经元都有权重 w 来表示它们的连接强度,且每个显层神经元都有表示自身权重的偏置系数 c ,每个隐层神经元都有表示自身权重的偏置系数 b 。因为 RBM 是基于能量的模型 EBM(Energy Based Model),所以可以用下面函数表示一个受限玻尔兹曼机的能量,并通过该能量函数引入一系列相关的概率分布函数:

$$E(v, h) = - \sum_{i=1}^{N_v} b_i v_i - \sum_{j=1}^{N_h} c_j h_j - \sum_{i,j=1}^{N_v, N_h} W_{ij} v_i h_j \quad (14)$$

在一个受限玻尔兹曼机中,激活隐层神经元 h_j 的概率密度函数为:

$$P(h_j | v) = \sigma(b_j + \sum_i W_{ij} v_i) \quad (15)$$

由于是双向连接,所以显层神经元可以被隐层神经元激活,其概率密度函数为:

$$P(v_i | h) = \sigma(c_i + \sum_j W_{ij} h_j) \quad (16)$$

式中: σ 为 Sigmoid 函数^[4],也可以设定为其他函数。由于同一层显性或隐性神经元之间无连接权重,故具有独立性,所以概率密度亦满足独立性,易得到下式:

$$P(h | v) = \prod_{j=1}^{N_h} P(h_j | v) \quad (17)$$

$$P(v | h) = \prod_{i=1}^{N_v} P(v_i | h) \quad (18)$$

通过以上的推导和分析得出了 RBM 的基本构造。

当用一条数据向量来训练完 RBM 的显性神经元层后,受限玻尔兹曼机会根据式(15)计算出相应的隐层神经元被激活的概率: $P(h_j | x) j=1, 2, \dots, N_h$,并且取 0-1 随机数 μ 作为阈值,若概率大于该阈值则神经元将被激活,否则会被抑制,即:

$$h_j = 1 \quad P(h_j | x) < \mu \quad (19)$$

$$h_j = 0 \quad P(h_j | x) \geq \mu \quad (20)$$

由以上不等式得出隐层的每个神经元是否被激活。

RBM 共有五个参数: v, h, b, c, W ,其中 v 是输入向量, h 是输出向量, b, c, W ,是通过学习相应数据得到的偏置值和权重。训练 RBM 采用的是 K 步对比散度算法 DC-k(Contrastive Divergence)^[5]。先将数据输入给显层 V_1 ,并使用式(15)计算出每个隐层神经元的激活概率值。然后从计算的概率分布中通过 Gibbs 抽样^[6]选取一个样本:

$$h_1 \sim P(h_1 | V_1) \quad (21)$$

并用 h_1 重新构造显层,因为显层和隐层之间为双向全连接所以可通过隐层反推出显层,最后使用式(16)计算出显层中的每个神经元的激活概率 $P(V_2 | h_1)$ 。再次在 h_1 的基础上计算得出新的概率分布并通过 Gibbs 抽样选取一个新的样本:

$$V_2 \sim P(V_2 | h_1) \quad (22)$$

利用 V_2 再次计算每个隐层神经元的激活概率,最后得到更新的概率分布 $P(h_2 | V_2)$ 的权重:

$$W \leftarrow W + \lambda (P(h_1 | V_1) V_1 - P(h_2 | V_2) V_2) \quad (23)$$

$$b \leftarrow b + \lambda (V_1 - V_2) \quad (24)$$

$$c \leftarrow c + \lambda (h_1 - h_2) \quad (25)$$

按照以上步骤经过若干次训练后,隐层神经元不但能较为精准地表达出显层神经元的特征,而且还能够在一定程度还原显层。

1.2.2 网络的训练与调优

DBN 在训练模型的过程中主要分为两步:

(1) 预训练:首先对第一个 RBM 进行完全训练,并将第一个 RBM 的偏移量和权值固定;然后将第一个 RBM 的隐层神经元的学习状态作为输入向量输入到第二个 RBM 中进行充分训练,在训练完第二 RBM 之后,将第二 RBM 设置在第一 RBM 的顶部;最后重复上述训练步骤任意次数,并需要分别对每一层的 RBM 网络进行无监督训练以确保将特征向量尽可能地映射到多个不同的特征空间,同时保留多个特征信息,若训练集为被标记的数据,那么在顶层训练 RBM 时,除了 RBM 显层中的神经元之外,需要加入表示分类标签的神经元,与 Softmax 分类器等一起进行训练。根据学习到的相应标签数据,分类器中相应的标签神经元被激活为 1,其他神经元被抑制为 0。

(2) 微调:在对组成 DBN 的 RBM 进行训练后,每层 RBM 只能保证自身的权值对该层得到最优的特征向量映射,并不能对整个 DBN 模型达到最优的特征向量映射,所以还需要计算出预测值和真实值之间的误差。这就要将 DBN 的输出层替换为反向传播层(BPNN)^[7],反向传播层会将误差值从上向下传播至每一层的 RBM,从而达到微调整个 DBN 网络的效果。将 RBM 学习到的特征向量作为其输入向量,并且对关系分类器进行有监督训练。上述训练 RBM 网络模型的过程也可以看作是对深层的 BP 神经网络^[13]权值参数的初始化,避免了 DBN 像 BP 神经网络一样因随机初始化权值参数而容易陷入局部最优和训练时间过长的缺陷^[13]。训练好的模型如图 4 所示,其中深色部分为参与训练最顶层 RBM 的标签。




图 4 训练好的深度置信模型

训练生成 DBN 模型后,除了顶层 RBM 以外,其他层 RBM 的权重都被分成了向下的生成权重和向上的认知权重,接下来使用醒睡算法 CWS(Contrastive Wake-Sleep)^[9]对模型调优。该算法主要分为两个阶段,醒阶段为学习和认知过程,通过学习外界的特征和向上的认知权重产生每一层的抽象表示的结点状态,并且使用随机梯度下降算法^[10]修改层间向下的生成权重。睡眠阶段为联想和生成过程,通过醒阶段学习和认知到的概念和向下的生成权重来生成底层状态的同时再修改层与层之间向上的认知权重。

2 实验效果与对比

以电磁继电器寿命实验数据的滤波来测试本算法效果。电磁继电器是指专门应用于电器控制的继电器,该类继电器切换负载功率大,抗冲、抗振性高。电磁继电器在航空航天等用电系统中担负着控制、调节和保护等极其重要的任务,其质量的好坏与工作的可靠性直接影响着各种用电设备整体运行的可靠性和安全性。由文献^[18]可知接触电阻、超程时间和弹跳时间是影响继电器寿命和可靠性的关键参数。执行大众集团 VW80932 标准工作模式:通电 2 s,断电 3 s。采用寿命试验台对德国海拉公司 HELLA/JD191 型常开式触点电磁继电器进行寿命实验,该样件动作 104 088 次失效^[11]。图 5 - 图 7 为该样件三个参数进行断点和野值^[12]的处理后的生命周期中退化趋势数据。




图 5 接阻电阻随动作次数的变化规律

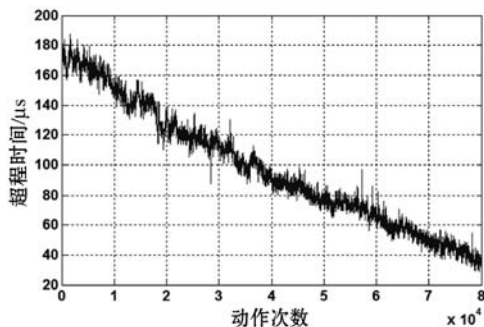


图 6 超程时间随动作次数的变化规律




图 7 弹跳时间随动作次数的变化规律

先后用新息自适应卡尔曼算法和基于 DBN 模型改进的卡尔曼算法对参数(接触电阻、超程时间和弹跳时间)进行滤波,前后效果对比如图 8 - 图 10 所示。可见,采用 DBN 模型对卡尔曼滤波算法的噪声协方差矩阵进行调整,改变了滤波增益并在线调整系统模型从而明显提高对数据中目标状态的估计精度。




图 8 接阻电阻随动作次数的变化规律滤波前后对比图




图 9 超程时间随动作次数的变化规律滤波前后对比图




图 10 弹跳时间随动作次数的变化规律滤波前后对比图

为了更直观地描述滤波的性能,使用均方根误差 RMSE^[20] (root mean square error) 进行定量分析,定义如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (26)$$

式中: n 代表实验次数, y_i 表示状态变量 \hat{y}_i 滤波状态值。图 11 - 图 13 给出了三个参数 100 次试验的 RMSE,可以看到使用基于 DBN 模型改进的卡尔曼算法对比使用新息自适应卡尔曼滤波算法的三个退化参数均方根误差有明显降低。




图 11 超程时间均方根误差对比图




图 12 弹跳时间均方根误差对比图




图 13 接阻电阻均方根误差对比图

从图 11 - 图 13 的三个参数 RMSE 曲线可以看出,采用 DBN 模型改进的卡尔曼滤波算法可以较好地降低 RMSE。通过使用 RMSE 曲线可以较好地分析和比较 DBN 模型对卡尔曼滤波算法的滤波增益,并且对基于不同神经网络模型改进的滤波算法提出一种较为理想的比较手段,同时也为后续进行滤波效果评估提供足够的依据。

3 结 语

实验使用 DBN 改进模型进行滤波后对结果进行分析和对比,提取了电磁继电器中的六个重要参数中具有代表性的三个参数为输入数据,建立基于 DBN 的新息卡尔曼滤波模型。滤波结果表明了该模型的精确性和有效性,根据仿真计算和实验的结果可以看出,基于深度置信网络改进的新息卡尔曼滤波模型是可行且有效的,可为继电器寿命预测、故障诊断以及其他相关设备器件的可靠性研究提供新的更高精度的数据处理方法。

参 考 文 献

- [1] Hammerschmidt M, Neuhaus A R, Rieder W F. The effects of material transfer in relays diagnosed by force and/or voltage measurement [J]. Components & Packaging Technologies IEEE Transactions on, 2004, 27(1):12 - 18.
- [2] 李忠良, 陈卫兵, 邹豪杰, 等. 基于新息的神经网络自适应卡尔曼滤波 [J]. 湖南工业大学学报, 2011, 25(1): 105 - 108.
- [3] 金光. 一种综合性能与寿命数据的 Bayes-Bootstrap 方法 [J]. 宇航学报, 2007, 28(3): 731 - 734.
- [4] 韩亚坤, 文鸿雁, 郭雷, 等. 基于神经网络的新息自适应卡尔曼滤波在高速公路变形监测中的应用 [J]. 桂林理工大学学报, 2017, 37(1): 136 - 139.
- [5] 陈辰. 基于卡尔曼滤波算法的短期风电功率预测 [D]. 乌鲁木齐: 新疆大学, 2015.
- [6] 郭峰峰. 基于虚拟样机技术的汽车电磁继电器静态特性研究 [J]. 电器与效能管理技术. 2014, 20(6): 20 - 37.
- [7] Bezručka J. The use of a Kalman filter in geodesy and navigation [J]. Slovak Journal of Civil Engineering, 2011, XIX (2): 8 - 15.
- [8] Haykin S. Adaptive filter theory [M]. 4th ed. Prentice-Hall, Inc., 2002.
- [9] 王洪斌, 王红, 何群, 等. 基于深度信念网络的风机主轴轴承状态监测方法 [J]. 中国机械工程, 2018, 29(8): 948 - 953.
- [10] 周志红. 基于深度学习的工业过程控制系统异常检测技术的研究 [D]. 北京: 北京邮电大学, 2018.

- [11] Haykin S. 神经网络原理[M]. 机械工业出版社,2004.
- [12] 李昌, 罗国阳. 结合支持向量机的卡尔曼预测算法在VRLA 蓄电池状态监测中的应用[J]. 电工技术学报, 2011, 26(11):168-174.
- [13] 张智儒. 面向情感分析的人脸表情识别系统的研究与实现[D]. 沈阳:东北大学计算机学, 2015.
- [14] 张珣, 何东阳. 基于深度信念网络的个人健康评估模型[J]. 软件导刊 2018, 10(17):45-47.
- [15] Hinton G E. A practical guide to training restricted boltzmann machines[J]. Momentum, 2010, 9(1):926-947.
- [16] Kuremoto T, Kimura S, Kobayashi K, et al. Time series forecasting using a deep belief network with restricted Boltzmann machines[J]. Neurocomputing, 2014, 137(15):47-56.
- [17] Huang W, Song G, Hong H, et al. Deep Architecture for Traffic Flow Prediction: Deep Belief Networks With Multi-task Learning[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5):2191-2201.
- [18] 张菲菲, 李志刚. 基于BP神经网络的继电器剩余寿命预测[J]. 低压电器, 2012, (01):11-14.
- [19] 单晶晶, 吴建军, 张晨, 等. 基于SVM和RBF神经网络的民航不安全事件组合预测方法[J]. 山东科学, 2014, 27(3):61-65, 72.
- [20] 韩萍, 桑威林, 石庆研. 一种新型非线性卡尔曼滤波方法[J]. 仪器仪表学报, 2015, 36(3):632-638.
- calization based on kinect camera in complex environment [C]//IEEE International Conference on Robotics & Biomimetics. IEEE, 2013.
- [4] Yang H, Song Z, Chen R. An incremental PCA-HOG descriptor for robust visual hand tracking [C]//International Conference on Advances in Visual Computing. Springer-Verlag, 2010:687-695.
- [5] Ji Y, Idrissi K. Automatic facial expression recognition based on spatiotemporal descriptors[J]. Pattern Recognition Letters, 2012, 33(10):1373-1380.
- [6] Wu X, Wang G, Cong Y. Object recognition method by combining color and depth information [J]. Transactions of the Chinese Society of Agricultural Engineering, 2013, 29(25):96-100.
- [7] Oreifej O, Liu Z. HON4D: Histogram of Oriented 4D Normals for Activity Recognition from Depth Sequences [C]//IEEE Conference on Computer Vision & Pattern Recognition. IEEE Computer Society, 2013:716-723.
- [8] Wang J, Liu Z, Chorowski J, et al. Robust 3D Action Recognition with Random Occupancy Patterns [C]//European Conference on Computer Vision. Springer-Verlag, 2012:872-885.
- [9] 王兵, 董洪伟, 张明敏, 等. 基于Kinect的动态手势识别[J]. 传感器与微系统, 2018, 37(2):143-146.
- [10] 巫康伟, 袁明新, 葛玉婷, 等. 一种联合几何特征和隐马尔可夫模型的手势识别算法[J]. 自动化技术与应用, 2017, 36(6):108-111.
- [11] Saon G, Chien J T. Bayesian Sensing Hidden Markov Models[J]. Audio Speech & Language Processing IEEE Transactions on, 2012, 20(1):43-54.
- [12] 包希日莫, 高光来, 张璟. 基于遗传算法的声学模型拓扑结构优化[J]. 计算机工程与应用, 2014, 50(14):5-8.
- [13] 郑斌珏, 赵辽英, 王毅轩. 基于Kinect深度信息的手指检测与手势识别[J]. 计算机科学与技术汇刊:中英文版, 2014(1):9-14.
- [14] 李艳萍, 宁跃飞, 杨伟. 基于限峰分离模糊直方图均衡化的图像增强算法[J]. 西南师范大学学报(自然科学版), 2018, 43(3):42-49.
- [15] Liu F, Du B, Wang Q, et al. Hand gesture recognition using kinect via deterministic learning [C]//Control and Decision Conference. IEEE, 2017:196-199.
- [16] Zhang B, Yang Y, Chen C, et al. Action Recognition Using 3D Histograms of Texture and A Multi-class Boosting Classifier[J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 2017, 26(10):4648-4660.

(上接第166页)

该系统的主要创新之处在于其较好的处理概率特征的能力。为了处理序列分布形式特征,将巴氏距离引入到BS-HMM中,通过极大似然法对提出的BDBS-HMM参数进行预估。同时也考虑到了模型正规化,使用EM算法推导出参数的递归解,并将所提出的BDBS-HMM与使用标准HMM和BS-HMM的手势识别效果进行比较,实验结果表明了在使用MSRGesture3D数据库的情况下所提出的BDBS-HMM的优越性。

参 考 文 献

- [1] Chen Y, Luo B, Chen Y L, et al. A real-time dynamic hand gesture recognition system using kinect sensor [C]//IEEE International Conference on Robotics and Biomimetics. IEEE, 2016:2026-2030.
- [2] Pisharady P K, Vadakkepat P, Loh A P. Attention Based Detection and Recognition of Hand Postures Against Complex Backgrounds[J]. International Journal of Computer Vision, 2013, 101(3):403-419.
- [3] Chen B, Huang Z, Yu W, et al. Object recognition and lo-