

# 浙江大學

## 本科生畢業論文



題目 電池系統數學建模研究

姓名與學號 陳凡 3120000248

指導老師 劉康生

年級與專業 數學與應用數學（英才班）1201

所在學院 數學科學學院



## 浙江大学本科生毕业论文（设计）诚信承诺书

1. 本人郑重地承诺所呈交的毕业论文（设计），是在指导教师的指导下严格按照学校和学院有关规定完成的。
2. 本人在毕业论文（设计）中引用他人的观点和参考资料均加以注释和说明。
3. 本人承诺在毕业论文（设计）选题和研究内容过程中没有抄袭他人研究成果和伪造相关数据等行为。
4. 在毕业论文（设计）中对侵犯任何方面知识产权的行为，由本人承担相应的法律责任。

毕业论文（设计）作者签名： 陈 凡

2016 年 5 月 15 日



## 本科生毕业论文（设计）任务书

一、 题目：电池系统数学建模研究

二、 指导教师对毕业论文（设计）的进度安排及任务要求：

2016-03-25 前完成问题需求调研、文献查阅。准确理解和把握需求，能对主要文献进行一定评述。完成数据准备和开题报告，其中回答下列问题：

（1）要做什么？（2）为什么要做？（3）相关研究别人是如何做的？（4）自己计划怎么做？

2016-05-08 前完成论文初稿。建立数学模型、设计求解算法、通过数据验证模型的有效性。

2016-05-25 前完成论文全部工作。

起讫日期 2016 年 3 月 10 日 至 2016 年 5 月 31 日

指导教师（签名）

职称

三、 系或研究所审核意见：

负责人（签名）

年 月 日



# 目录

摘要.....	9
Abstract.....	11
正文.....	13
第一章 绪论.....	13
1. 阀控铅酸电池 .....	13
2. 课题研究背景和研究意义 .....	15
3. 国内外研究现状 .....	17
第二章 基于数据驱动的稳横放电电池模型.....	21
1. 数据驱动方法概述 .....	21
2. 电池放电模型建立与参数识别 .....	21
3. 稳横放电电池模型分析 .....	25
4. 本章小结 .....	27
第三章 基于粒子滤波的定额间歇放电电池模型.....	27
1. 粒子滤波方法概述 .....	27
2. 定额间歇放电电池模型 .....	30
3. 模型效果和实证分析 .....	32
4. 本章小结 .....	33
第四章 基于人工神经网络的变额放电电池模型.....	33
1. 神经网络概述 .....	33
2. 变额放电电池模型 .....	34
3. 模型效果和实证分析 .....	35
4. 本章小结 .....	36
第五章 总结、展望与致谢.....	37
1. 总结 .....	37
2. 展望 .....	37
3. 致谢 .....	37
参考文献.....	41



## 摘要

阀控铅酸电池保留了铅酸电池成本低廉、性能稳定的特点；相比普通铅酸电池，阀控铅酸电池简单易用，具有更高的便携性。此外，阀控铅酸电池的使用过程中无需添加电解液，只会产生少量的气体，人工维护成本大大降低，这些特性为阀控铅酸电池带来了很大的市场空间。

由于阀控铅酸电池在出厂销售之后鲜有拆解需求，所以阀控铅酸电池在使用过程中能够获取的实时数据仅有电池路端电压、电流，这对于阀控铅酸电池的使用状况的监测带来了新的挑战。为了实现电池的剩余有效使用时间进行预测，本文基于数据驱动的建模方法对三种不同放电条件和外部环境的放电过程加以描述，并讨论了各个模型的模型求解方法、参数识别过程，最后基于实验数据进行电池模型的实证分析。

具体来说，对于稳横放电过程，建立综合放电模型（IMD），将模型应用于实际应用的工业电池进行模型分析，得到电池模型的平均修正相对预测误差率为 0.0446。对于定额间歇放电过程，利用基于粒子滤波算法的模拟电池放电模型，对电池剩余有效使用时间进行预测，得到较好的逼近效果。最后，对于变电流放电场景，利用 BP 神经网络，设计电池放电神经网络模型对电池放电过程训练并预测电池剩余有效使用时间，将问题求解模型进一步泛化。将电池在其他放电电流下的实验数据用于训练模型，并将 60A 放电电流作为测试样本利用模型进行预测，得到的测试结果说明模型的修正相对预测误差率为 0.0639。

## 关键词

阀控铅酸电池 剩余有效使用时间 数据驱动方法 粒子滤波 神经网络



## Abstract

Valve-controlled lead-acid battery retains the lead-acid battery characteristics of low cost and usefulness, compared with the ordinary lead-acid batteries, with higher portability and simplicity. Valve control lead-acid battery in use need not the electrolytic solution supplement, with only a small amount of gas produced. Consequently, its maintenance cost has been greatly reduced. These features for valve-controlled lead-acid battery has brought great market space.

As there is no need of dismantlement while valve-controlled lead-acid batteries are in use, one can only obtain real-time data of terminal voltage, current, which has brought new challenges for Remaining Useful Life (RUL) estimation of battery. In order to forecast the RUL, three modeling methods based on the data driven for three different discharge conditions and external environment of the discharge process have been developed. Discusses on solutions of each model, parameter identification process are also addressed. Finally, analysis of the battery model based on some experimental data is given.

In particular, for constant discharging process, we devised the Integrated Discharge Model (IMD), which was applied to the Narada 500P battery. We also evaluate the model by obtaining an average of Adjusted Relative Prediction Error Rate (ARPER) to 0.0446. As for norm intermittent discharge process, a model based on particle filter algorithm is developed to forecast the battery RUL, which turns out to be a good approximation. Finally, for variated discharging scenario, a neural network base battery model was devised, which further generalizes previous model. Using experimental data of Narada 500P batteries in other discharge flow as the training dataset, and the testing set of 60A discharge current, the results corroborate our model with an ARPER equals to 0.0639.

## Key Words

Lead-acid Battery, Remaining Useful Life, Neural Network, Particle Filter



## 正文

# 第一章 绪论

## 1. 阀控铅酸电池

阀控铅酸电池自于 20 世纪 70 年代诞生以来, 在一些发达国家已经形成了相当的生产规模, 很快就完成了产业化并大量投放市场。这种电池虽然也是铅酸蓄电池, 但是它与原来的铅酸蓄电池相比具有很多优点, 因而倍受用户欢迎。为了满足电源系统的需求, 工艺上提高铅酸电池的比功率, 新型铅酸蓄电池如卷绕式、双极性、水平式以及超级电池等在性能上相对传统铅酸蓄电池改进和完善了许多双极柱卷绕式阀控铅酸蓄电池已经作为动力电池或者电力系统储电、后备电力等诸多场景下发挥作用。阀控铅酸电池的主要技术特点包括: (1) 密封程度高, 电解液象凝胶一样被吸收在高孔率的隔板内, 不会轻易流动, 所以电池可以横放; (2) 阀控式密封铅酸蓄电池的极板栅采用无镉铅合金, 电池的自放电系数很小; (3) 电池的正负极板完全被隔板包围, 有效物质不易脱落, 使用寿命长; (4) 阀控式密封铅酸蓄电池的体积比老式电池小, 而容量却比老式敞开型电池高; (5) 电池在长期运行中无需补充任何液体, 同时在使用过程中不会产生酸雾, 气体, 维护工作量极小; (6) 电池的内阻较小, 大电流放电的特性好。

相比于其他类型的电池, 阀控铅酸电池还有独特的产品优势。首先, 阀控铅酸电池使用过程极大的优于一般地铅酸电池。阀控式密封铅酸蓄电池只需严格控制整流器的充电电压, 根据浮充使用和循环使用的不同要求, 采用规定的电压进行恒压充电, 无需值班人员过多操心电池的充电过程, 不必添加蒸馏水, 也不必经常检测电池端电压、电解液比重及温度, 只需定期检测电池端电压和放电容量即可。阀控铅酸电池在初始装配上也很方便。阀控式密封铅酸蓄电池已进行过化成充放电处理, 荷电出厂, 所以用户在安装使用时, 无需再进行繁琐的初充电过程, 如果放置时间超过六个月, 可按生产厂的规定进行补充电, 在充足电之后, 进行一次容量试验性放电检查, 以判断电池容量是否符合标准要求, 质量是否稳定可靠。其次, 在安全性上, 阀控铅酸电池更具优势。阀控式密封铅酸蓄电池采用密封结构, 可竖放或卧放使用, 无酸雾、无毒、无有害气体溢出, 由于电池采用恒压充电制, 电池内部实现氧循环过程, 水损失很少, 即使偶尔过充, 有少量的气体可通过安全阀向外排出, 电池壳不致因压力过大而鼓胀甚至爆裂。最后, 阀控铅酸电池的运营维护成本低廉。阀控式密封铅酸蓄电池不污染设备和环境, 可与电子设备放在一起使用, 无须专门用于电池放置和维护的房间, 维护工作量大大减少。而且电池安装可采用叠放式电池架, 占地面积小, 节约电源系统的投资费用。

阀控铅酸蓄电池的极栅主要采用铅钙合金, 以提高其正负极析气 ( $H_2$  和  $O_2$ ) 过电位, 达到减少其充电过程中析气量的目的。正极板在充电达到 70% 时, 氧气就开始

发生,而负极板达到 90%时才开始发生氧气。在生产工艺上,一般情况下正负极板的厚度之比为6:4,根据这一正、负极活性物质量比的变化,当负极上绒状 Pb 达到 90%时,正极上的  $\text{PbO}_2$  接近 90%,再经少许的充电,正、负极上的活性物质分别氧化还原达 95%,接近完全充电,这样可使 $\text{H}_2$ 、 $\text{O}_2$ 气体析出减少。采用超细玻璃纤维(或硅胶)来吸储电解液,并同时为正极上析出的氧气向负极扩散提供通道。这样,氧一旦扩散到负极上,立即为负极吸收,从而抑制了负极上氧气的产生,导致浮充电过程中产生的气体 90%以上被消除(少量气体通过安全阀排放出去)。

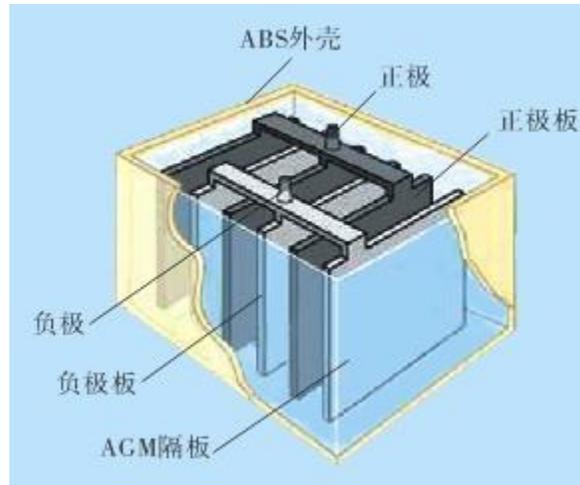


图 1 阀控铅酸电池

我国、日本、德国工业用电池采用 10 小时率,美国的工业用电池标准为 8 小时率。我国电力、邮电标准规定,10 小时率电池,1 小时率时容量为  $0.55 C_{10}$ 。20 小时率电池,10 小时率时容量为  $0.93 C_{20}$ ,1 小时率时容量为  $0.56 C_{20}$ 。电力系统一般在设计上均选用 10 小时率铅酸蓄电池,而 UPS 电源在设计上则选用 20 小时率铅酸蓄电池。

工业电池可分为两类:一类为深循环使用的电池,另一类为浮充使用的“备用电源”电池。循环使用的电池以深循环次数来表示其使用寿命,以  $0.8 C_{10}$  深度充放电循环使用的电池,其寿命达到 1200 次以上;而浮充使用的电池,年限可达到 10~12 年,有的可达到 15~20 年。蓄电池只有 80%容量时认为寿命终止。由于观察不到阀控式密封铅酸蓄电池内部的情况,因此在使用中应定期对其进行放电试验,以检测蓄电池容量,避免因其容量下降而起不到备用电源的作用。需要注意的是蓄电池在放电时不要过放电,放电后必须在 12h 内补充电,否则将造成蓄电池的永久损坏。

## 2. 课题研究背景和研究意义

### 2.1. 电池管理系统

近年来，在国内外市场的驱动下，我国铅酸蓄电池产业持续高速增长，已经成为世界最大的铅酸蓄电池生产国、出口国和消费国。然而，因受到电池回收、环境污染等问题的困扰，铅酸蓄电池行业与市场近年来饱受诟病。浙江南都电源公司是中国通信电源行业规模化、现代化的典型企业，和具有良好发展潜力的新能源生产企业之一。公司主营业务为通信后备电源、动力电源、储能电源、系统集成及相关产品的研发、制造、销售和服务；主导产品为阀控密封蓄电池、锂离子电池、燃料电池及相关材料。产品广泛应用于通信、电力、铁路等基础性产业；太阳能、风能、智能电网、电动汽车、储能电站等战略性新兴产业；电动自行车电池、通讯终端应用电池等民生产业。南都电源目前的主要业务为阀控密封蓄电池及锂离子电池，同属于二次电池范畴。其中，阀控密封蓄电池属于铅酸电池类别。铅酸蓄电池由于具有容量大、安全可靠性强、大电流放电性能优越、使用温度范围广、再生循环利用高等突出优点，在化学电源中始终占主导地位，整个产业不断增长，目前已占据了二次电池市场的 75%（功率数）。由于它在经济性、大容量、大功率放电、使用安全性方面的优势是其他各类电池难以替代的，因此今后仍将在蓄电池市场的发展中保持稳固的地位。

该公司成立以来，始终高度重视技术工作，已形成科学合理的技术创新机制和创新氛围，培养了具有丰富理论和实践经验的核心技术团队，具备很强的自主创新和产品开发能力。公司实行“研发一代、储备一代”的研发策略，在对现有产品改进细化的同时，持续进行电源领域前驱性技术的研究，在行业内占据着技术前沿。公司将技术优势有效地转化为产品的综合优势，为公司近几年的快速发展提供了有力的保证。同时，南都电源高度重视基础研究，以基础研究推动技术进步与工艺改进，不断推出新技术、新产品，积极开拓新应用市场，保证了公司发展的可持续性，有效保持着产品在市场中的竞争优势。

本课题选用的实验阀控铅酸电池在国内领先成为阀控技术的带头人，公司希望能够将其自主研发的产品的使用时间预测系统进行进一步提升，已达到更精确的判断电池在当前使用情况下所能够继续工作的时间。出于阀控技术的固有特性和技术成本考虑，在电池使用阶段，无法对其内部结构和工作材料进行实时监测，电池系统仅能够对于电池工作时的电压、电流和温度进行实时测量，以期实现预测目的。在仅有三种数据的情形下，希望得到一个准确的 SOC 估计方法给项目开展带来了很大的困难，但是如果成功解决 SOC 在线预测的问题，将为整个产业带来可观的推动力。

为了实现这一重大技术突破，公司已经投入大量研发精力于训练样本的设计和基础数据的采集。已经形成了给定电池型号，放电电流和初始电量状态 SOC 的条件下的放电曲线图（电压 V/时间 t 图）。公司希望充分利用已有的放电曲线图，设

计预测电池在当前工作状态下，还能持续工作的时间的数学模型，并在今后，将其应用于不同型号电池的电池管理系统(BMS)中。

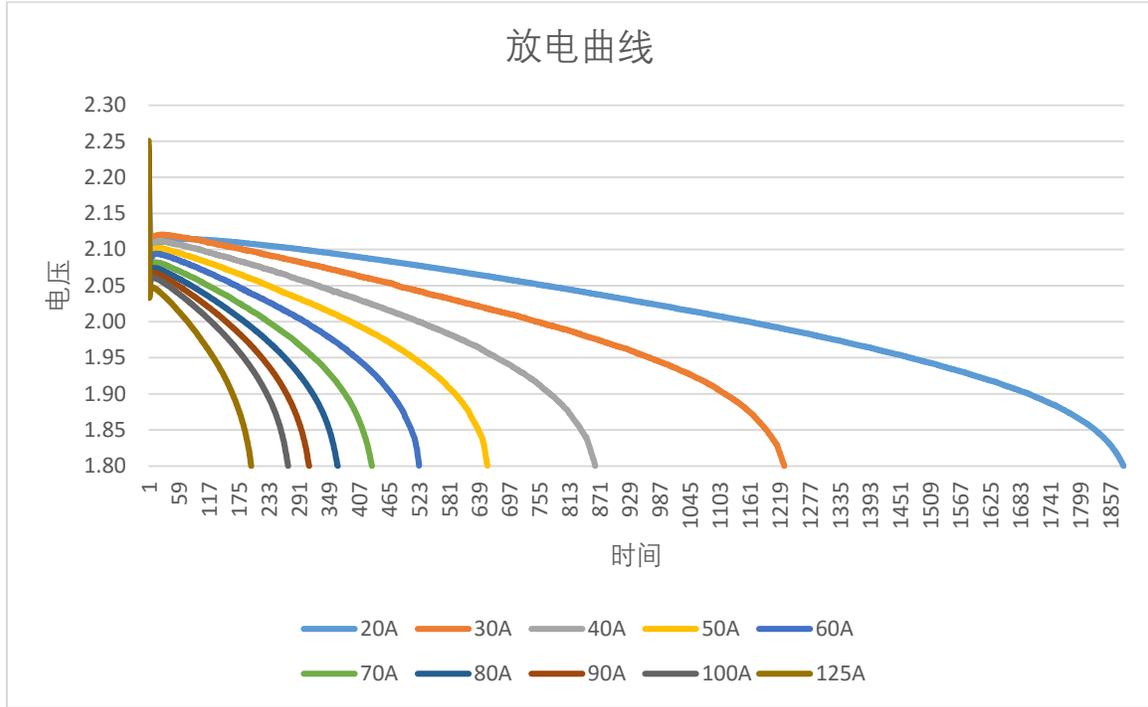


图 2 电池放电曲线

## 2.2. 前沿数学专题讨论

本课题的设计背景基于前沿数学专题讨论“数据分析与决策优化中的数学问题”，旨在通过深入研究专题讨论中所设计的机器学习方法，将其应用到现实生活场景，解决实际问题，从而达到加深对特定的统计学习方法的理解，提升解决实际问题的能力的目的。

在课题设计中，分别着重关注了数据驱动建模方法、粒子滤波和人工神经网络。在不同的问题场景中，通过分析不同的提醒建模方法，比较通过改进的模型和已有电池模型之间的比较，实证分析了数据驱动模型分析的功能和应用价值。

## 2.3. 电池剩余有效使用时间及其重要性

电池剩余使用时间(Remaining Useful Life, RUL)的估计对于用户和电池维护人员对于电池的工作状态的把控至关重要。用户或工作人员只有在准确知道正在工作或者工作后静息一段时间后的剩余有效使用时间，才能够及时更换电池或为电池充电做好准备。电池管理系统(Battery Management System, BMS)需要准确把握电池的剩余有效使用时间，才能对电池状态进行评估，及时预警和采取相应的措施。要做到这一点，首先需要对电池的电量状态进行数学建模和科学描述。

电池电量状态是电池使用一段时间或长期搁置不用后的剩余容量与其完全充电状态的容量的比值(State of Charge, SOC), 常用百分数表示, 其取值范围为 0~1。当 SOC 为 0 时表示电池放电完全, 当 SOC 为 1 时表示电池完全充满。控制蓄电池运行时必须考虑其电池电量状态。有效的在线评估电池电量状态, 不仅可以结合电池的浮充电压来评估电池的使用情况, 更可以为电池管理系统的功能设计提供必备的信息和有用的参考。

从更长远的角度来说, 电池的整个生命周期都在经历着不断的老化和耗损, 所以电池的实际工作能力也在不断地减小。更形象地说, 电池的实际工作能力可以比喻成电池的健康状况, 它随着电池的反复使用逐渐退化, 最终成为健康状况不良的电池, 也就是报废电池。虽然在工业设计和实际生产中, 用户和厂家更加关心的是电池的剩余有效使用时间或电量状态, 但是电池的健康状况(State of Health, SOH)直接决定了电池的 SOC 变化特性。所以, 研究电池的 SOH 成为电池系统的使用时间预测的一个必要环节。通常使用电池的实际工作能力与其额定(理想)的工作能力之间的比值作为电池健康状况 SOH 的描述。由于电池健康指数的定义还没有明确的行业规定, 所以有时也有将 SOH 进行定性界定的情况, 例如崭新、半新、稍旧、老旧、报废等。

通过学习数据分析和统计学习方法, 基于实验数据对电池剩余有效使用时间和电池电量状态进行建模与预测, 是我们的核心目标。

## 2.4. 创新性

基于电池的测试数据, 首先利用数据驱动的建模方法, 电池稳横放电条件下的放电曲线进行数学建模, 并利用最优化方法对模型进行参数识别, 并得到了比较令人满意的预测结果。

利用参考文献中提出的非线性物理模型, 创新地将粒子滤波算法应用于阀控铅酸电池的剩余有效使用时间的预测中, 相较于利用拓展卡尔曼滤波算法对非线性系统进行求解, 具有更高的理论精确度。

利用神经网络对不同电流大小的放电环境进行建模学习, 实现了阀控铅酸电池放电模型中电流参数的参数化, 对于给定的合理范围内放电电流的放电曲线进行预测, 将电池模型的实际应用范围进一步推广。

## 3. 国内外研究现状

电池 SOC 估计的研究有很多, 其中对 SOC 估计的大多数是针对锂电池[1], 少部分会讨论动力铅酸蓄电池, 而关于传统汽车铅酸蓄电池 SOC 的研究就更少。这是由于电池的性能差异以及蓄电池在汽车上的地位决定, 铅酸蓄电池的能量密度等特性不如其他动力电池, 而且自放电特性严重, 估算起来相对比较困难。另一方面,

锂电池由于其放年性能稳定，导致放电曲线通常处于平台，而仅在电池电量接近耗尽时才会出现快速的电压下降的现象。

传统 SOC 估算方法中，有些方法无法在线估计，譬如开路电压法和放电试验法，这些方法只能在驻车状态下对电池内部状态离线估计，由于做不到在线估计，该方法的使用往往受限于实验室环境，而有些方法的估计误差不足，譬如安时积分法[2]中存在累积误差，内阻法的估计误差对铅酸电池来说很大。传统方法虽然存在不足，但是简单容易实现，通过改进还有发展空间。通过安时积分法、开路电压法及负载电压法的结合，就能满足电池 SOC 在线估计[3]。

随着计算机技术的发展，复杂的算法和程序已经可以在控制系统中实现，基于神经网络[4]、模糊控制理论[5]和卡尔曼滤波法的 SOC 估算方法成为如今理论研究的热点。

类型	方法
直接测量	<ul style="list-style-type: none"> <li>• 化学计算</li> <li>• 开路电压测量</li> <li>• 抗阻法（负载电压法）</li> </ul>
安时测量法	<ul style="list-style-type: none"> <li>• 库仑计算法</li> <li>• 修正库仑计算法</li> </ul>
状态估计法	<ul style="list-style-type: none"> <li>• 卡尔曼滤波</li> <li>• 粒子滤波</li> <li>• 状态观测法</li> <li>• 模糊控制理论</li> </ul>
统计学习方法	<ul style="list-style-type: none"> <li>• BP 神经网络</li> <li>• 支持向量机</li> <li>• 相关向量机</li> </ul>

### 3.1. 电流积分类

由于电量是电流与时间的乘积，电流累积法包括放电试验法和安时积分法。开路电压方法是指用恒定电流进行连续放电，直至端电压低于放电截止电压，放电电流与时间的相乘等于放出的电量。对于铅酸电池而言，有一个粗糙的线性关系估计，即：

$$V_{OC}(t) = a_1 \times SOC(t) + a_0,$$

其中， $SOC(t)$ 为时刻 $t$ 的电池电量， $a_0$ 为电池的路端电压。遗憾的是，电池的 $V_{OC}(t)$ 和 $SOC(t)$ 并不能总保持相同的关系，因为他们的关系会根据不同的电池类型而不同。

安时积分法和放电法原理相同。由于电量是电流对时间的积分，实时记录电池的充放电电流并对其进行积分，从而得到电池消耗或者获得的电量，若电池工作前的剩余电量为 $SOC_0$ ，那么当前时刻 $t$ 的电池 $SOC(t)$ 为

$$SOC(t) = SOC_0 + \frac{1}{C_A} \int_{t_0}^t (I_b - I_l) d\tau = SOC_0 + \frac{1}{C_A} \int_{t_0}^t \eta i d\tau$$

其中 $C_A$ 为电池标定容量； $I_b$ 为电池充放电电流； $I_l$ 为电池反应过程中消耗的电流； $\eta$ 为电池充放电效率，在充电过程中损耗电流不可忽略，充放电效率小于1，需要用大量的充放电试验才能确定[6]。安时积分法可以应对变电流的电池 $SOC$ 估计，因此可以用于在线估计。

### 3.2. 状态估计类

状态估计类方法以卡尔曼滤波方法为代表，通过利用可测量的数据，用估计值无限逼近最优值。

卡尔曼滤波法：在事先了解系统一定先验知识的条件下，根据电池模型建立系统的状态空间方程，用测量的输出值，就能获得系统状态（对电池系统来说，可以将 $SOC$ 作为状态量之一）的最优估计。根据电池放电试验，可以采集到电池的端电压和电流，建立以电池 $SOC$ 为状态量的系统方程，经过状态估计时间更新、均方误差时间更新、系统输出先验估计、滤波增益矩阵计算、最优状态估计、均方误差估计几个步骤，就能得到 $SOC$ 的最优估计。

卡尔曼滤波法在线性方程模型下可以证明能够给出准确的解。但是，电池系统十分复杂，其动力学方程的表达形式实际上并不是一个线性方程。在这样的情况下，卡尔曼滤波给出的预测解将会和实际待预测对象存在较大的偏差。因此，在选择预测方法和建立电池动力学模型的时候需要十分慎重，所以可以考虑利用粒子滤波实现改进。

状态观测法：当工作电流变化剧烈时，如果将电流看作电池状态空间模型的输入，那么使用状态观测器[6]可以很好地对这种情况下 $SOC$ 进行高精度观测。利用电池的输入电流和输出电压信号来计算电池内部不能测量的信号，状态量是包括 $SOC$ 在内的电池内部信号。

状态观测法涉及需要识别的模式非常复杂，多种可能的放电曲线代表的是类似地内部激励现象。另一方面一种放电曲线也有可能对多种预测结果具有解释型意义。因此，再利用状态观测法是，往往需要整合多种放电曲线的相态现象，综合评价。为此，不得不设计出一种有效的学习方法才能把一系列复杂的有待识别的模式通过有层次的关系整理出来，这就是本课题考虑从多层次神经网络的作为一个可能的切入点的原因。

### 3.3. 统计学习方法

人工神经网络(artificial neural networks, ANN)是由许多神经元按照某种规则相互连接而形成的一种人工智能网络系统,是一种基于数据的、典型的非线性方法[7],具有自组织和自学习能力强的特点,丰富的改进算法广泛应用于多种非线性预测领域。根据 ANN 的非线性自主学习功能,利用大量数据样本对神经元进行训练,调整其连接权值和阈值,确定数据模型并进行 RUL 预测。

上述对 ANN 的不同改进方法在取得了较好的预测效果的同时,仍然存在如下不足:(1)ANN 结构本身固有问题:ANN 易收敛于局部极值,且当特征空间维数增高时导致的运算量急剧增长问题难以解决。作为一种新型递归神经网络的回声状态网络(echo state networks, ESN)采用储备池结构代替传统神经网络的隐含层,将低维输入空间映射到高维的状态空间,解决了训练效率低导致其难以在现实中应用的问题,Liu 等人[9]提出了一种集成单调回声状态网络方法,解决了 ESN 实现锂离子电池 RUL 预测输出不稳定的问题,取得了较好的预测效果,但是实际应用中 ESN 仍然存在储备池及网络参数复杂难以确定问题。(2)ANN 的网络结构难以确定,且需要大量数据进行训练以确定网络结构,或根据先验知识确定。(3)ANN 往往仅能给出 RUL 预测的点估计值,不具备预测结果的不确定表达能力,虽然文献[102]通过改进方法实现了 ANN 进行 RUL 预测的不确定性表达,但并没有从根本上解决不确定性的管理问题。(4)ANN 算法对于小样本数据的预测能力较差。

支持向量机(support vector machine, SVM)在 VC 维理论基础,采用结构风险最小化作为最优准则,能够获取全局最优解[10]。SVM 克服了 ANN 存在局部极值、收敛速度慢、网络结构难以确定以及需要大样本进行训练。

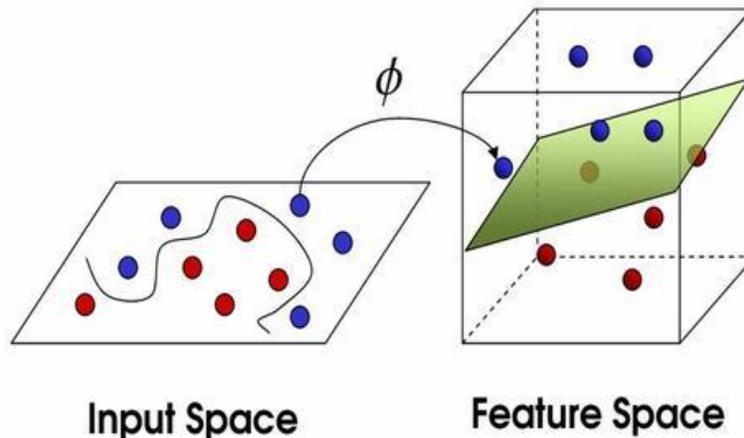


图 3 支持向量机

SVM 自身仍然存在许多不足:如核函数必须满足 Mercer 条件、稀疏性有限、支持向量的数目对误差边界敏感、惩罚因子和损失函数复杂难以确定等。同样,SVM 也缺乏不确定性的表达和管理能力。

## 第二章 基于数据驱动的稳横放电电池模型

作为本文所讨论所有问题的基础，我们首先对稳横放电条件的电池进行建模分析，此后的模型都是本章内容的发展。

### 1. 数据驱动方法概述

为了描述电池放电曲线样本的数据特征，希望得到一种在给定了某一放电曲线之后能够通过简单的参数形式描述该曲线的方法。数学模型的用户可以在不深入了解电池工作机理的情况下（或者在内在机理相关参数难以获取或者客观不可测量的情况下），利用某一放电曲线的实验测量数据，得到描述电池放电模型参数化曲线，从而把握电池放电情况的直观规律。

基于数据驱动模型的方法主要是利用生产过程中产生的丰富的采集数据，根据多元统计分析理论、神经网络等理论建立输出变量与其它过程可测量之间关系的模型。该方法的优点是，采用各个理论建立的模型具有统一的模型结构，并且建模方法比较简单，不需要深入了解过程的反应机理，并且准确性较高；其缺点是由于其基于数据的原理，模型的泛化能力较差。从数据驱动的方法的这些特性我们可以看出，由于本课题的研究对象——阀控铅酸电池所能够测量的数据局限性（仅能实时测量其路端电压和电流）的角度，数据驱动建模方法是一个理想选择。

常见的数据驱动建模方法有：线性/非线性回归模型、神经网络模型、偏最小二乘回归、以及支持向量机等。在诸多数据驱动数学建模方法中，各个算法之间优势互补，可以提高模型的准确性和稳定性(Robustness)。

对参数的估计是数据驱动方法的核心。模型参数识别最早是针对线性系统而提出的，对于非线性系统使用线性参数识别方法往往会导致较大的误差，这也是近年来学术研究的热点课题。在控制理论领域中，非线性系统的参数识别主要围绕优化理论为基础发展起来的系统参数求解。本课题也将利用优化理论对电池放电模型进行求解。

### 2. 电池放电模型建立与参数识别

对于给定的电池型号（本课题使用基于某电池厂某型号电池的实验数据进行模型检验和分析），在稳定的放电电流 $I$ 下持续放电。期望通过数据驱动的建模方法，对电池的放电曲线 $V = f_V(t)$ 进行描述。我们首先约定稳定放电条件的含义如下：

- 假设 1：电池处于稳定的放电状态，即电流 $I = I_0$ 恒定，电池外部温度恒定。

对于一条放电曲线，用户关注更多的部分往往是电池进入稳定放电状态，为此我们提出进一步假设：

- 假设 2: 根据行业常规, 铅酸电池放电路端电压降为 1.8V 时停止放电, 称为停止电压。设电池从开始稳定放电时刻 $t_0$ 到停止放电 $t_N$ 为一个完整的放电过程, 取 $[t_0, t_N]$ 为放电时间。其中, 忽略电池刚开始接入放电电路阶段的电池极化等特殊过程引起的电压波动。

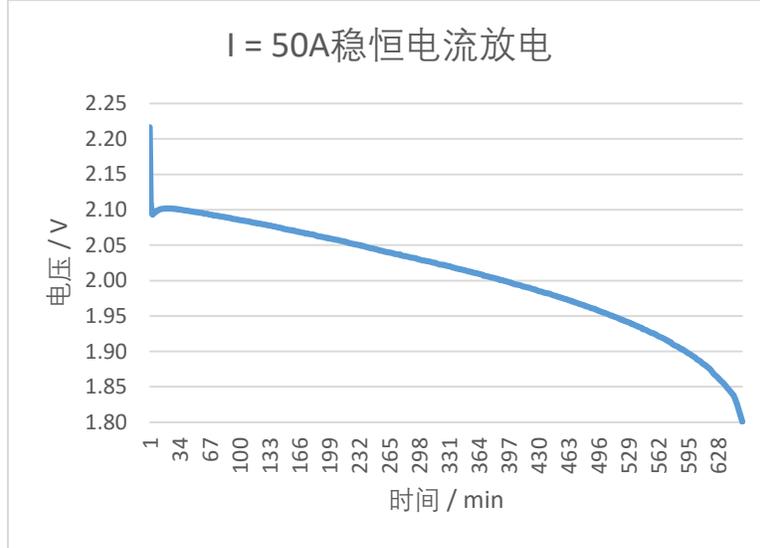


图 4 放电曲线示例

通过观察图 2 或图 4 中的电池放电曲线, 我们不难发现阀控铅酸电池在稳恒电流的放电条件下的放电曲线具有良好的单调性和光滑性。为了更好地表达预测目标, 我们可以等价地将放电曲线的反函数作为模型建立的对象, 即放电时间关于路端电压的函数 $t = f_v^{-1}(V) = f_t(V)$ 。由此, 我们所感兴趣的剩余有效使用时间就可以通过最大放电时间与已放电时间的差值 $T_N - t$ 来描述。

根据之前所提到的放电曲线良好的光滑性, 我们初步尝试建立**指数放电模型** (Exponential Discharge Model, EDM):

$$t_{EDM} = \beta_1 \exp(\beta_2 V + \beta_3) + \beta_4,$$

进一步, 利用牛顿法[11]对模型中的参数进行识别。我们首先实验电池对的放电曲线实验数据进行模型效果的测试和分析。图 5 和表 1 中给出了指数放电模型的结果的预测效果, 值得注意的是, 放电模型的预测曲线在放电即将结束的部分, 即电压接近 1.8V 的曲线左端出现比较严重的偏移。而作为电池放电模型, 用户更关注的恰恰是这段“敏感区域”, 准确预测电池即将放电结束部分的剩余有效使用时间, 对于准确预警、提示更换电池至关重要。为此, 考虑进一步改进指数放电模型在低电压附近的表現。

表 1 EDM 参数识别

模型参数	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_4$
参数识别	-0.0443	5.4526	-1.6061	870.5781

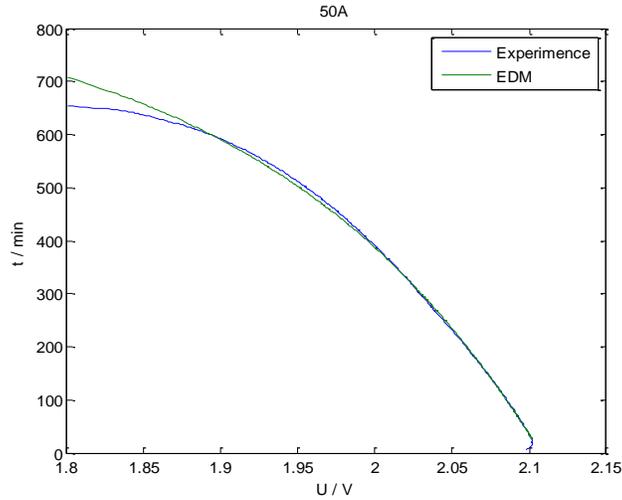


图 5 EDM 模型效果

通过进一步观察阀控铅酸电池放电曲线的特性，我们不难注意到电池放电模型在接近终止电压部分常常出现“骤降”。这一特性是由于电池的内在物理结构和放电原理所决定的，大多数电池所共有的问题。在不深入了解电池内在工作原理的情况系，希望通过模型设计的角度对曲线进行更进一步的拟合，我们考虑为模型增加一个纠错项。注意到指数放电模型（或者泛化到更一般的指数模型）在零点附近以及负轴部分的描述能力快速下降，这是由于指数衰减的特性所决定的，为此，我们考虑为模型增加线性纠错项目，旨在为零点附近的低电压部分改进模型。从而，我们得到如下的改进指数放电模型（Improved Exponential Discharge Model, IEDM）：

$$t_{IEDM} = \beta_1 \exp(\beta_2 V + \beta_3) + \beta_4 V + \beta_5$$

我们仍然利用牛顿法进行非线性模型参数识别。

表 2 IEDM 参数识别

模型参数	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_4$	$\beta_5$
参数识别	-2.1	2.6	1.9	3481.8	-4172.2

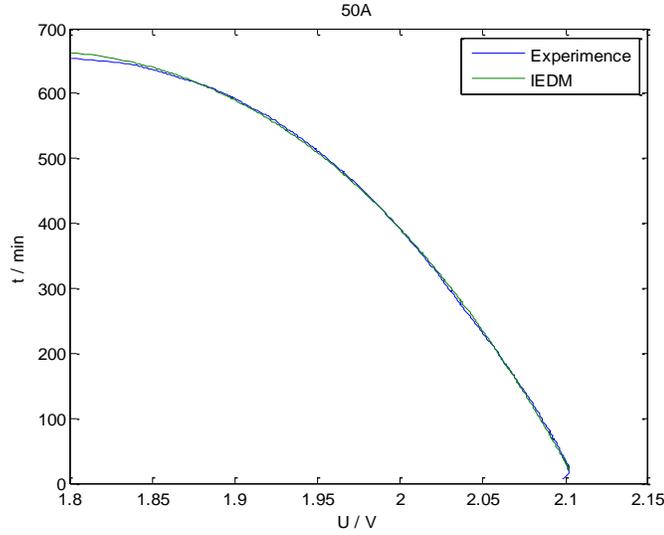


图 6 IEDM 模型效果

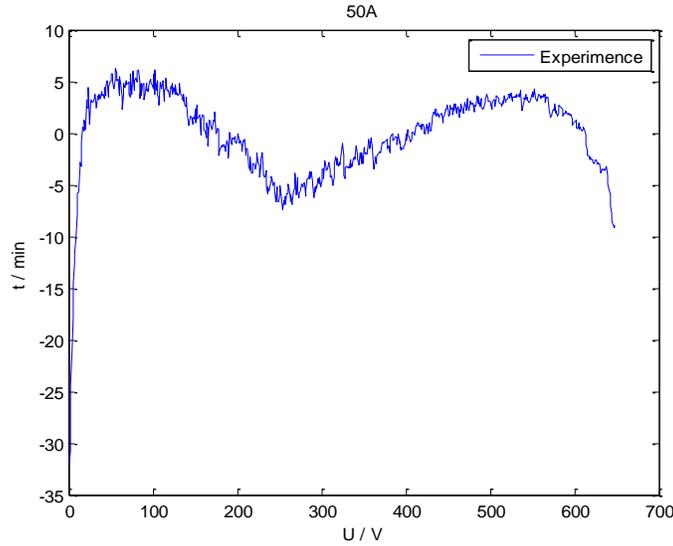


图 7 IEDM 预测残差图

从图 6 和表 2 中我们不难看出改进指数放电模型的效果提升。然而，此时我们还不能说的到了一个电池放电模型。为了进一步提升模型在低电压部分的预测效果，我们转而观察模型的预测残差图（图 7），从中我们很容易发现残差  $t_{err}(V) = t^*(V) - \hat{t}(V)$  的变化趋势，即具有一个正弦函数周期特性。受到一现象的启发，我们进一步改进 IEDM 模型，为其增加一个三角函数的逼近项，得到综合放电模型（Integrate Discharge Model, IDM）：

$$t_{IDM} = \beta_0 + \beta_1 \exp(\beta_2 V + \beta_3) + \beta_4 V + \beta_5 \sin(\beta_6 V + \beta_7),$$

图 8 和表 3 中给出了综合放电模型的参数识别结果和预测效果，从预测残差图（图 9）中，我们可以看到随着电池放电电压接近停止电压，综合放电模型的预

测效果逐渐趋优，并稳定于实验观测路端电压附近。这说明 IDM 达到了一个比较理想的电池 RUL 预测效果。

表 3 IDM 参数识别

模型参数	$\beta_1$	$\beta_2$	$\beta_3$	$\beta_4$	$\beta_5$	$\beta_6$	$\beta_7$	$\beta_8$
参数识别	-2.8	2	2.2	-16.9	-1029.7	3.2	23.5	645.9

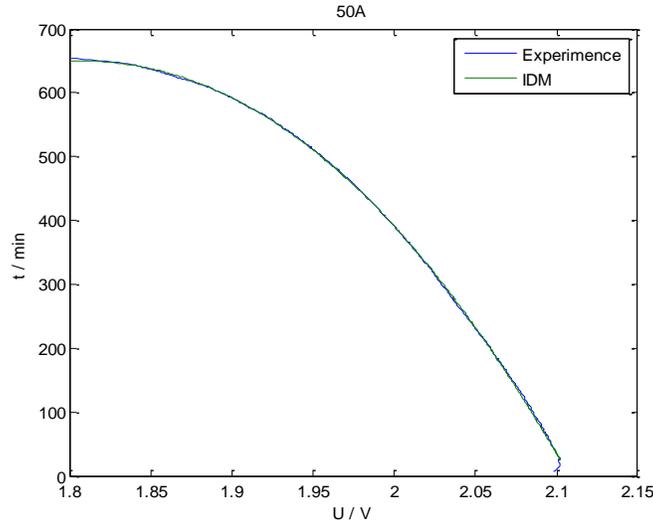


图 8 IDM 模型效果

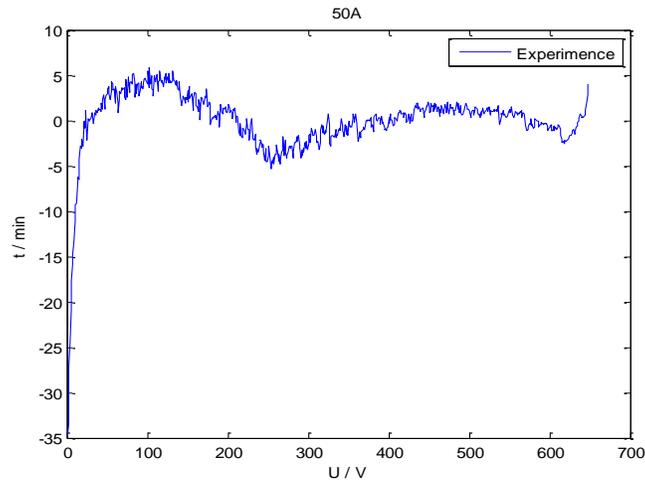


图 9 IDM 预测残差图

### 3. 稳横放电电池模型分析

为了客观评估综合放电模型的表现，我们给出平均相对预测误差和修正相对预测误差率。

对于给定放电电流下的放电曲线样本 $(V_i, t_i), i = 0, \dots, N$ , 设通过模型预测得到的相应的已放电时间为 $\hat{t}_i$ , 则平均相对预测误差为

$$R = \mathbb{E} \left( \frac{|t_i - \hat{t}|}{t_i} \right),$$

其中 $\mathbb{E}(\cdot)$ 为数学期望函数。对于综合放电模型 IDM 我们有 $\hat{t}_i = t_{IDM}(V_i)$ , 则

$$R_{IDM} = \frac{1}{N} \sum_{i=1}^N \frac{|t_i - t_{IDM}(V_i)|}{t_i}.$$

平均相对预测误差反映了电池放电模型对于所有样本的相对误差的公平效果, 它是电池放电模型对实验观测结果的解释程度的直接表现。当 $R = 0$ 时, 说明电池模型完全刻画了阀控铅酸电池的放电特性, 我们称这样的电池模型为**理想观测电池模型**, 因为它仅从外部数据完整给出了电池放电的工作机理。很显然, 我们可以利用  $N-1$  阶多项式函数对电池放电曲线进行求解得到理想观测电池模型, 但是, 显然这样的数据驱动模型存在严重的过拟合现象, 为此我们不在这方面过分苛求。

表 4 不同电流下 IDM 模型平均相对预测误差 $R_{IDM}$

$I$	30A	40A	50A	60A	70A	80A
$R_{IDM}$	0.0588	0.0530	0.0482	0.0441	0.0354	0.0282

通过计算 (见表 4), 我们可以看到 IDM 方法得到的电池模型的平均相对预测误差为 $R_{IDM} = 0.0482$ . 这说明 IDM 对于阀控铅酸电池的放电过程的描述具有比较高的解释性。

观察电池放电曲线我们不难发现, 当我们使用时间作为预测对象, 并将路端电压作为预测输入的时候, 由于电池在接近停止电压附近会出现比较剧烈的下降, 导致在等之间间隔采样的背景下, 停止电压附近的采样点会变得稀疏; 相对应的, 在我们不太关心的距离停止电压比较远的部分, 由于电压下降相对缓慢, 在等时间间隔采样下会出现密集的采样点, 这就导致了我们的计算平均相对预测误差的时候偏向于用户并不太关心的阶段, 对于我们更加关心的停止电压附近的评价相对宽松。为此, 我们需要对平均相对预测误差进行修正。设 $V'_0, \dots, V'_N, (V'_0 = V_0, V'_i - V_{i-1} = 0.001V)$ 为理想的电压采样点, 其中 $V'_N$ 为停止电压。我们需要在评价预测效果前, 对观测样本进行筛选过滤, 抽取子样本 $(V''_i, t''_i) \cup (V_N, t_N)$ , 其中 $V''_i$ 是对某 $1 \leq k \leq N$ , 满足

$$V''_i = \min\{V_i \mid V_{k-1} \leq V_i < V_k\}, 1 \leq i \leq K$$

的样本。由此, 我们给出**修正相对预测误差率**为

$$\bar{R} = \mathbb{E} \left( \frac{|t_i'' - \hat{t}|}{t_i''} \right),$$

同样，对于 IDM 预测结果，有修正相对预测误差率

$$\bar{R}_{IDM} = \frac{1}{K} \sum_{i=1}^K \frac{|t_i'' - t_{IDM}(V_i'')|}{t_i''}.$$

修正相对预测误差率是对于电池放电模型拟合效果的一个更加平衡的评价标准。表 5 给出了 IDM 的修正相对预测误差率结果，从结果不难看出，IDM 对于稳横放电条件下的阀控铅酸电池的表达准确性高。

表 5 不同电流下 IDM 模型平均相对预测误差  $\bar{R}_{IDM}$

$I$	30A	40A	50A	60A	70A	80A
$\bar{R}_{IDM}$	0.0747	0.0605	0.0516	0.0449	0.0289	0.0210

## 4. 本章小结

阀控铅酸电池的综合放电模型是基于数据驱动的数学建模方法，该方法不依赖于电池内部物理和化学机理，通过实验数据的观察，和严谨小心的模型推理验证。模型具有以下应用优势：首先，模型本身简洁易懂，对于不具备深入的电池机理知识的用户仍然适用。利用数据本身提供的信息进行建模，参数识别的过程简单易行，达到了很好地解释效果，在同一类型的电池中具有一定的泛化性。其次，模型在完成了参数识别后，仅需进行简单的运算即可完成剩余有效使用时间的预测，且效率较高，在工业实现上可操作性强。

但是，该基于数据驱动的建模方法要求放电过程稳恒电流，对于模型假设的要求比较高，这为模型的进一步泛化推广应用产生了限制。模型本身是基于实验数据发展起来的，因此对于实验测量的精度和准确性依赖性相对较高。

## 第三章 基于粒子滤波的定额间歇放电电池模型

在上一章中，我们探究了电池在稳横放电电流下的放电曲线特性，在这一章中，我们进一步探究电池在定额电流，放电却存在间断的条件下的电池放电模型。

### 1. 粒子滤波方法概述

粒子滤波 (Particle Filter) [12] 算法来源于蒙特卡洛方法 (Monte Carlo method)，它是利用粒子集来表示概率，可以用在任何形式的状态空间模型上。其核心思想是通过从后验概率中抽取的随机状态粒子来表示其分布情况，是一种顺序重要性采样法 (Sequential Importance Sampling)。

1) 理论基础：概率分布的重要性采样表达

图 10 来形象地表示概率密度的加权采样表达。在概率密度函数曲线下方的黑点的位置表示了样本的取值，黑点的大小则表示了样本所带权重的大小。不难注意到，样本密集的区域和具有较大权重样本所处的区域都对应概率密度高的区域。

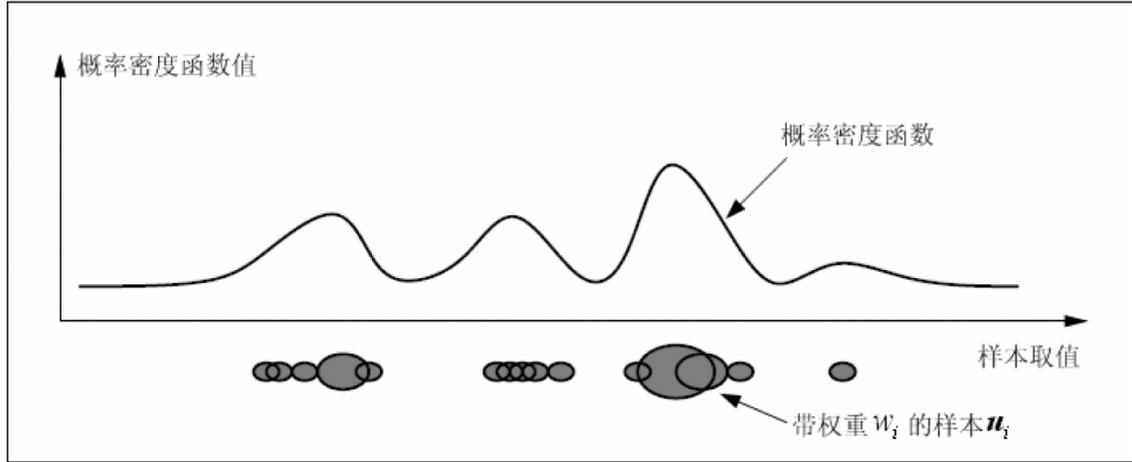


图 10 概率密度的加权采样表达图示

利用概率分布重要性抽样表达，可以导出粒子滤波算法的重要理论基础。假设未知变量 $X$ 的概率密度函数为 $f(x)$ ，另有一个容易实施的采样分布 $s(x)$ ，将两者用所谓重要性权重 $w_i = f(u_i)/s(u_i)$ 联系起来，其中 $u_i$ 是从 $s(x)$ 采样获得的样本，共有 $N$ 个。我们有变量 $X$ 的任意函数 $g(\cdot)$ 下的数学期望和条件概率密度函数

$$\frac{1}{N} \sum_{i=1}^N g(u_i)w_i = \int g(U)f(U)dU$$

$$\int p(U | V = v_0)g(U)dU \approx \frac{\sum_{i=1}^N p(V = v_0 | u_i)g(u_i)w_i}{\sum_{i=1}^N p(V = v_0 | u_i)w_i}$$

即后验采样的重要性权重

$$w'_i = p(V = v_0 | u_i)w_i.$$

这意味着，若已知了先验分布的采样表达 $\{u_i\}$ 与相应的 $w_i$ ，则 $\{u_i\}$ 与按上式定义的相应的 $w'_i$ 即为后验分布的采样表达。

2) 初始化阶段

在跟踪前需要选定要跟踪的目标物体，这个过程可以用人工划定方法和自动识别方法。使用人工的方法可以通过鼠标在图像区域标记出一片感兴趣矩形然后计算它的特征；使用自动的方法就是目标检测技术，识别出图像中要跟踪物体的大致位置。

对于粒子滤波的初始化过程我们可以假设成为筛选的过程，我们既可以不分优劣随机公平的生成备选粒子；也可以人为地在优秀的粒子中迭代生成新的粒子，即在指定的 ROI 中放粒子；或者采取类似模式识别的方法，通过概率分布选取表现优秀的粒子。这些采样出来的粒子就是对当前后验概率的一种近似。

### 3) 转移阶段

使用粒子滤波算法来对目标进行跟踪，即是通过前一次的先验概率来估算出当前环境下的后验概率密度，这个过程也是由粒子来完成的。通过模型设定的转移方程，当前阶段的每个粒子能够进行一次状态转移，进入下一阶段的粒子筛选过程。当前粒子的分布不可能跟上一帧时的分布一模一样，但是他们确实应该分布在上一帧位置的大致周围，这个变异过程就叫做**转移**。

粒子滤波的转移方程与卡尔曼 (Kalman) 滤波相似：

$$\begin{aligned}x_k &= f(x_{k-1}) + w_k \\y_k &= h(x_k) + v_k\end{aligned}$$

上式称为**状态转移方程**，下式的为**观测方程**， $w_k$ 和 $v_k$ 是高斯噪声。在算法的实现中并不是用的这个方程，使用他们的 1 阶或者 2 阶自回归方程。与卡尔曼滤波的不同之处在于转移方程中的函数 $f$ 和 $h$ 可以是非线性函数，在这样的假设下，卡尔曼滤波得到的结果往往误差较大，而粒子滤波方法的表现则优很多。

### 4) 决策阶段

转移阶段可以理解为通过上一阶段新生成的粒子的评价过程。在得到下一阶段的真是测量数据之后，通过一个决策过程，根据先前设定的误差评价标准，可以筛选出与新的观测值拟合度比较好的粒子作为优等粒子加以保留，并剔除误差较大的粒子。决策的方法根据不同的需求会不同，例如代码中使用距离作为衡量的标准，同时计算出来的相似度或者说分数就是相应粒子的权重。每一个粒子都需要计算其权重

$$w'_i = p(V = v_0 | u_i)w_i,$$

再将其归一化。

### 5) 重采样阶段

在资源有限的情况下，粒子滤波算法会淘汰权值低的粒子，让权值高的粒子来产生出更多的粒子，这就使得算法朝着权值高的地方收敛。假设有 200 个粒子，1 号粒子的权重为 0.01 而 2 号粒子的权重为 0.004。于是在重采样阶段，1 号粒子生孩子的指标是  $0.01 \times 200 = 2$ ，2 号粒子的指标是  $0.004 \times 200 = 0.8$ ，可以发现，1 号粒子除了刚产生的粒子外还要再额外的产生一个粒子，而 2 号粒子就再没有机会了。如此，最后得到的 200 个粒子即为所求，然后取个加权平均就得到了目标的状态值。

粒子滤波的思想与遗传算法的思想异曲同工，但是在操作粒子之间的相互影响产生新的粒子的过程中所使用的技术方法有些不同。电池 SOC 预测可以看成是概率分布的参数求解，从这个观点出发，粒子滤波方法将是一个有效的选择。

## 2. 定额间歇放电电池模型

在实际生产生活中，电池的应用往往不是一个完整的放电过程。也就是说，用户需要进行预测的对象往往不是持续不间断的放电过程，而是需要对带有间断（静息）过程的放电过程进行剩余有效使用时间的预测。电池在静息状态和放电状态之间的两端电压是在浮充电压和放电电压之间不断转换。

幸运的是，通过实验数据测量（见图 11），我们发现电池在放电过程中的间隔并不会对放电曲线造成本质影响。为此，我们既可以对被放电间隔分割的两段曲线进行简单的平移将其拼接起来，再利用第二章中介绍的综合放电模型对电池进行建模和参数识别，最终实现剩余有效使用时间预测。

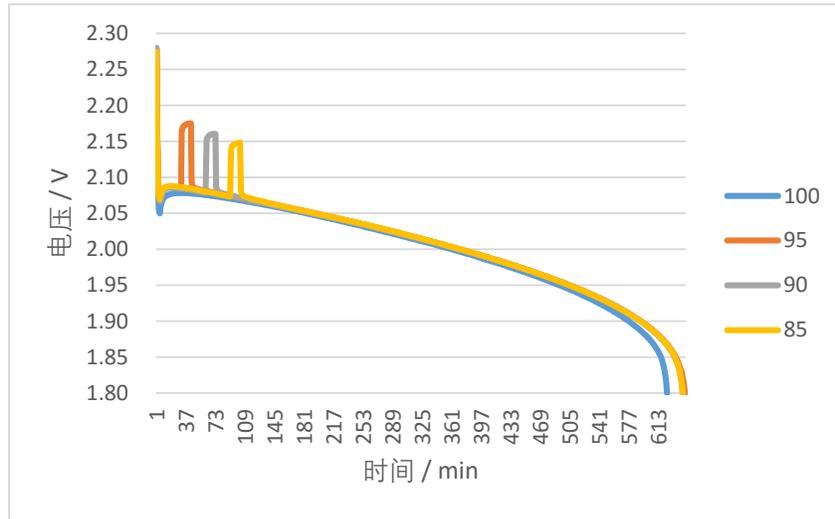


图 11 实验电池放电间隔测试

下面我们着重讨论一种基于粒子滤波算法的剩余有效使用时间预测方法。方法首先以电池的路端电压为对象进行预测，再利用预测所得的下一期路端电压作为实验观测电压输入到综合放电模型 IDM 中，得到下一期的剩余有效使用时间的预测值。该方法能够避免对放电曲线进行切割和平移所带来的人工误差，并通过粒子滤波对非线性电池模型进行逐步优化学习。

在文献[13]中，Bhangu 等人首先讨论了一个可证实有效的基于电池工作机理的非线性 RC 电池模型（图 12），该模型的学习对象是电池的内部电压和路段电压。随后作者利用拓展卡尔曼滤波(Extended Kalman Filter)的方法，对非线性电池模型进行系统参数学习。

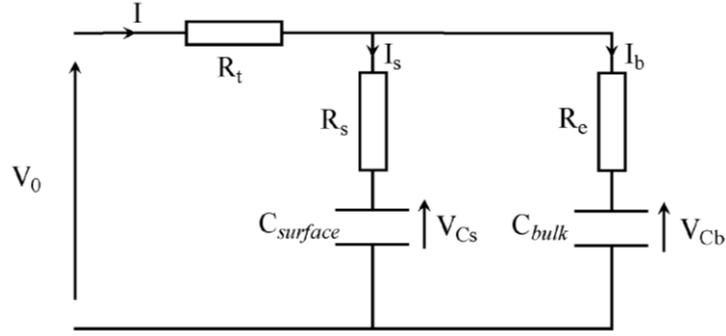


图 12 非线性电池模型等效电路图

设模型的状态变量为  $x = [V_{Cb}, V_{Cs}, V_0, \alpha]'$ ，可观测变量为  $V_0$ ，系统的转移方程为

$$\begin{aligned}\dot{x} &= f(x, u), \\ y &= C(x),\end{aligned}$$

其中，

$$f(x, u) = \begin{bmatrix} -\frac{V_{Cb}\alpha}{R_e + R_s} + \frac{V_{Cs}\alpha}{R_e + R_s} + \frac{IR_s\alpha}{R_e + R_s} \\ \frac{1}{C_{surface}} \left[ \frac{V_{Cb}}{R_e + R_s} - \frac{V_{Cs}}{R_e + R_s} + \frac{IR_e}{R_e + R_s} \right] \\ V_{Cb} \cdot f_1 + V_0 \cdot f_2 + I \cdot f_3 \\ 0 \end{bmatrix}$$

$$f_1 = -\frac{R_s\alpha}{(R_e + R_s)^2} + \frac{R_e}{C_{surface}(R_e + R_s)^2} - \frac{R_s^2\alpha}{R_e(R_e + R_s)^2} + \frac{R_s}{C_{surface}(R_e + R_s)^2}$$

$$f_2 = \frac{R_s\alpha}{R_e(R_e + R_s)} - \frac{1}{C_{surface}(R_e + R_s)}$$

$$f_3 = \frac{R_e^2}{C_{surface}(R_e + R_s)^2} - \frac{R_s R_t \alpha}{R_e(R_e + R_s)} + \frac{R_t}{C_{surface}(R_e + R_s)} + \frac{R_e R_s}{C_{surface}(R_e + R_s)^2}$$

和

$$\begin{aligned}C(x) &= V_0 \\ \alpha &= \frac{1}{C_{bulk}}.\end{aligned}$$

首先，我们可以利用粒子滤波方法对该非线性模型进行滤波学习，其次，实时地将预测所得的电池电压输入到第二章中所讨论的总和电池放电模型进行电池剩余有效使用时间的预测。模型中参数的初始化方法利用到了电池一个部分放电过程（见图 13），具体求解方法详见文献[13]的附录部分。

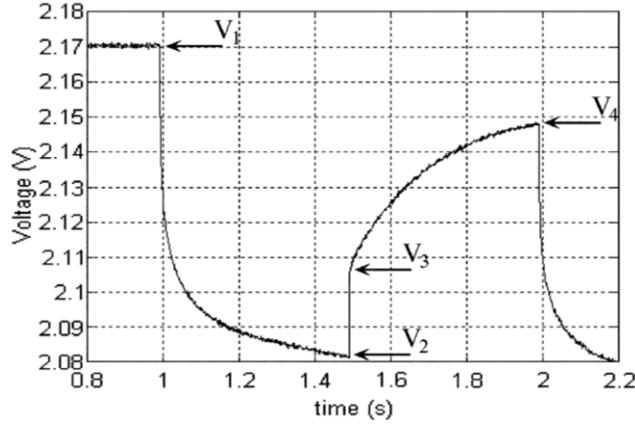


图 13 部分放电过程重要参数识别

### 3. 模型效果和实证分析

我们将基于粒子滤波的定额间歇放电电池模型应用于实验电池，为了检验电池对间歇放电的解释能力，我们对电池从满电量状态（100%SOC）开始放点，直到电池电量下降到 75%时，暂停放电 100 分钟，再重新以相同的放电电流对电池放电，并记录电池路端电压。

历史实验测得的放电曲线数据，结合第 2 节中讨论的非线性电池模型结合粒子滤波算法进行预测，图 14 展示了粒子滤波算法。从图中我们可以看出，粒子滤波算法对于带有间歇放电过程的电池路端电压预测具有较高的精确度。

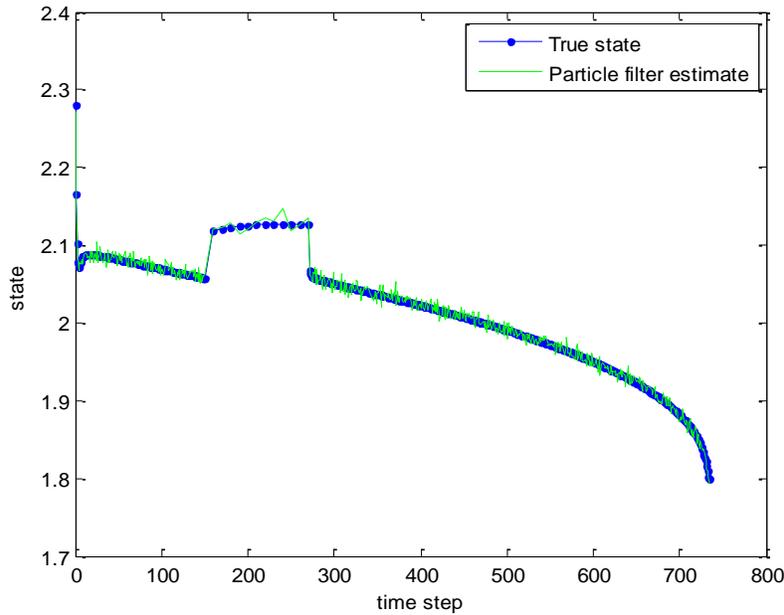


图 14 粒子滤波算法效果

## 4. 本章小结

我们创新地将粒子滤波算法应用于非线性电池模型的电池放电曲线分析中，基于粒子滤波的额定间歇电池模型具有诸多的模型优势。通过考虑允许暂停间隔，该模型在更大程度上允许电池放电状态的变化，使得电池模型所使用的范围得到扩充，具有宽阔的应用空间。其次，该模型的求解算法为滤波算法，具有运算效率高的特点，此外滤波算法还可以通过算法设计得到进一步优化。

另一方面，对于非线性转移模型，粒子滤波算法虽然具有比拓展卡尔曼滤波算法更优的求解效果和稳定性，但是作为滤波算法，它仍然面领着更高要求精确预测的挑战。此外，模型仍然对电流的大小做出了约束，有待进一步改进。

## 第四章 基于人工神经网络的变额放电电池模型

在前两章中，我们探究了电池在定额放电电流（间断或不间断）下的放电模型，在这一章中，我们着重讨论给定某些放电电流大小的放电曲线后，如何预测不同的放电电流下电池放电特性的电池模型。

### 1. 神经网络概述

神经网络（Artificial Neural Network, ANN）是 20 世纪 80 年代以来人工智能领域兴起的研究热点。它从信息处理角度对人脑神经元网络进行抽象，建立某种简单模型，按不同的连接方式组成不同的网络。在工程与学术界也常直接简称为神经网络或类神经网络。神经网络是一种运算模型，由大量的节点（或称神经元）之间相互联接构成。每个节点代表一种特定的输出函数，称为激励函数（activation function）。每两个节点间的连接都代表一个对于通过该连接信号的加权值，称之为权重，这相当于人工神经网络的记忆。网络的输出则依网络的连接方式，权重值和激励函数的不同而不同。而网络自身通常都是对自然界某种算法或者函数的逼近，也可能是对一种逻辑策略的表达。

由于传统的神经网络的结构比较简单，作为神经网络的发展，得益于并行计算和大规模集群计算机的发展，我们尝试提供层次更多、结构更复杂的神经网络成为可能。层次更多的神经网络的优势在于可以用较少的参数，较简单的函数形式，通过叠加和复合表示出复杂的函数。

在监督学习中，以前的多层神经网络的问题是容易陷入局部极值点。如果训练样本足够充分覆盖未来的样本，那么学到的多层权重可以很好的用来预测新的测试样本。但是很多任务难以得到足够多的标记样本，在这种情况下，简单的模型，比如线性回归或者决策树往往能得到比多层神经网络更好的结果（更好的泛化性，更差的训练误差）。

非监督学习中，以往没有有效的方法构造多层网络。多层神经网络的顶层是底层特征的高级表示，比如底层是像素点，上一层的结点可能表示横线，三角；而顶层可能有一个结点表示人脸。一个成功的算法应该能让生成的顶层特征最大化的代表底层的样例。如果对所有隐藏层同时进行训练，时间复杂度会太高；如果每次训练一层，偏差就会逐层传递。这会面临跟上面监督学习中相反的问题，会严重欠拟合。为了实现深层神经网络的参数估计，可以使用栈式自编码方式（逐层贪婪训练法）对参数进行初步估计，再利用微调多层自编码算法进行整体参数的修正与校准。这样，自编码器就能更好地学习到输入数据的特征。

在今后的课题开展中，深度学习（深度神经网络）有可能成为一个努力的方向，希望通过提高神经网络的层次功能，达到更好的 SOC 预测效果。当然人工神经网络这一类方法，在结果解释上比较依赖于主观理解。在很好的数据预测或判别效果下，当前并没有一种普遍可行的解释神经网络隐藏层所训练出的特征神经元的一般方法，神经网络更像是一种纯粹的统计学工具，而忽略了问题背景的丰富内涵，为此我们将神经网络方法作为变额放电电池模型的主要方法。

## 2. 变额放电电池模型

在第二章中，我们希望建立数学模型来描述电池放电过程中的关系： $t = f_t(V)$ ，并得到了一个满意的结果。在这一章中，我们希望通过统计学习方法对不同放电电流条件，在没有时间数据的基础下进行剩余有效使用时间的预测，即对变量关系  $t = f(V, I)$  进行学习。

相比第二章中的模型条件，此处有两个主要的泛化内容：首先，我们将学习对象的函数由一元关系提升到了高纬度的关系的学习，在函数参数空间的建立上将变得更加复杂多变；另一方面，我们需要对没有样本的变量进行预测，具体来说就是给有限个已知电流大小的放电曲线，希望利用这些数据对另一个任意给定的电流大小放电条件下的电池剩余有效使用时间进行预测。

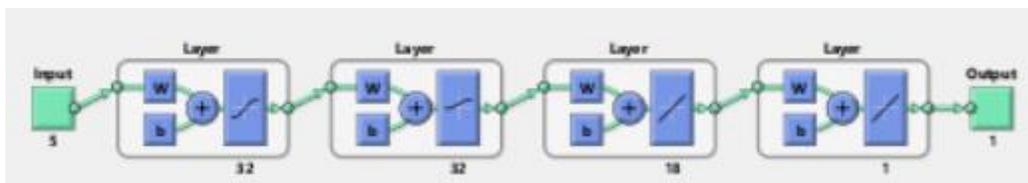


图 15 神经网络结构

为了实现这一目标，我们仍然选用数据驱动的建模方法，主要使用层次较丰富的人工神经网络对给定的电池数据进行数学建模。假设可供作为训练样本的数据结构如下：若干条实验观测电池放电曲线数据，由组成  $(t_i, V_i, t_i)_k$ ，其中， $1 \leq k \leq K, 1 \leq i \leq N_k$ ， $K$  为作为学习样本放电曲线条数， $N_k$  为第  $k$  条放电曲线的观测次数。

图 15 给出了设计的人工神经网络结构，电池放电模型神经网络由四个神经元层组成，分为输入层、两个隐藏层和一个输出层。我们设计五个输入数据分别为  $V_i$ ,  $I_i$ ,  $I_i^2$ ,  $V_i I_i$ ,  $V_i I_i^2$ ，神经网络期望输出值为  $t_i$ ，输入层共由 32 个神经元组成，使用双曲正切 S 形函数作为激活函数，第一个隐藏层共有 32 个神经元组成，使用对数 S 形转移函数作为激活函数，第二个隐藏层含有 18 个神经元，使用线性函数作为激活函数，而输出层包含的一个神经元，同样使用线性函数作为激活函数。我们采用梯度下降自适应学习率训练函数对神经网络进行训练，设置学习率为 0.01，最大迭代次数为 1500 次，将学习目标设定为  $MSE \leq 0.01$ 。

### 3. 模型效果和实证分析

我们将实验电池在 20A、30A、40A、50A、70A、80A、90A、100A、125A 稳恒放电条件下的实验测量数据作为上一节中介绍的神经网络的训练样本，输入数据分别为  $V_i$ ,  $I_i$ ,  $I_i^2$ ,  $V_i I_i$ ,  $V_i I_i^2$ ，期望输出值为  $t_i$ 。将该型号电池在 60A 放电电流下的放电曲线作为测试样本进行结果分析。

图 16 和图 17 给出了神经网络训练过程分析和训练的结果评价，包括拟合效果和预测效果，其中模型训练的拟合优度为  $R = 0.99933$ 。我们随后将经过训练的神经网络应用于 60A 放电曲线进行测试，得到的预测曲线与实验测量数据的比较如图 18 所示。同样的，我们计算基于神经网络的电池放电模型的修正相对预测误差率为

$$\bar{R}_{ANN} = 0.0639$$

从修正相对预测误差率来看，基于神经网络的电池放电模型较好地对电池变额电流放电进行了描述和预测。

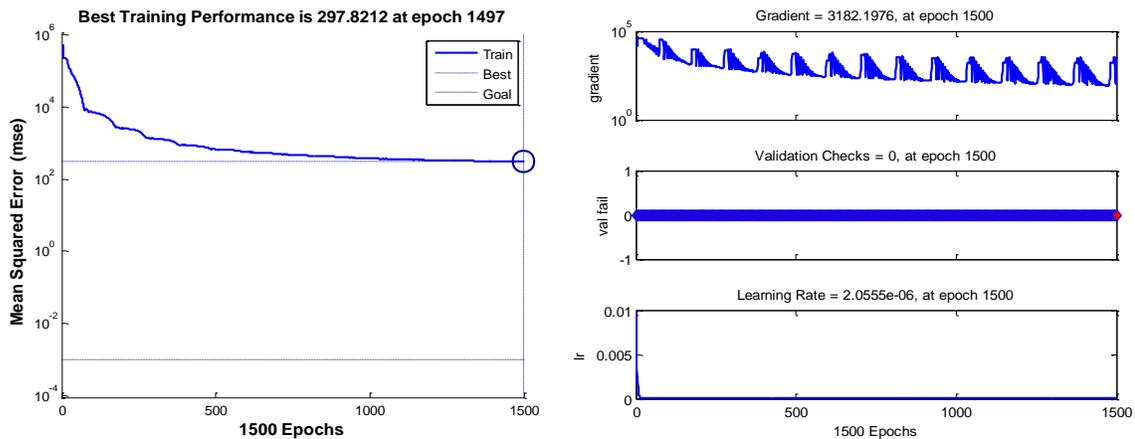


图 16 神经网络训练过程分析

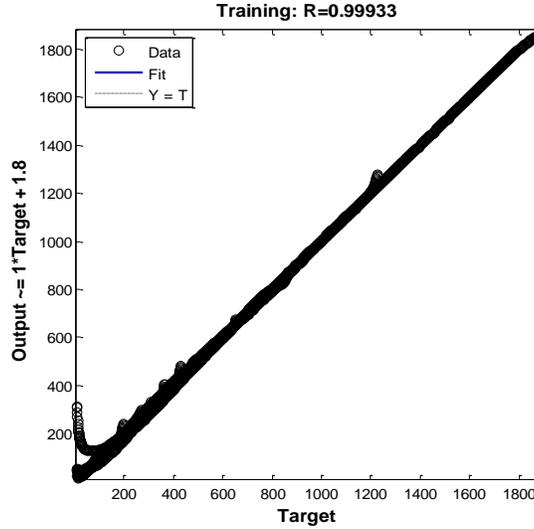


图 17 神经网络拟合优度评价

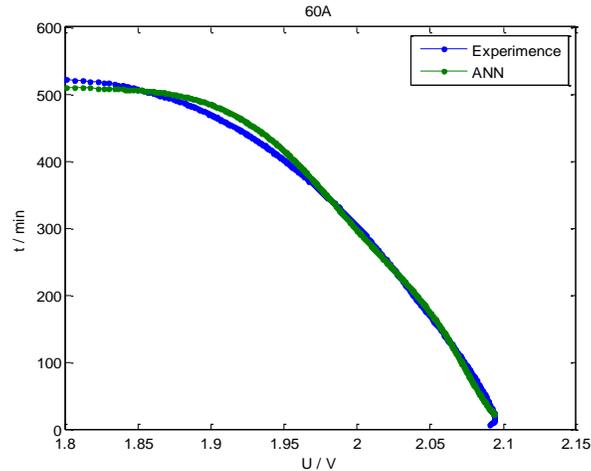


图 18 神经网络预测效果

#### 4. 本章小结

利用人工神经网络，建立变额电流电池放电模型是数据驱动建模方法的一个有效办法，该模型进一步将两种电池放电剩余有效使用时间预测的条件放宽，具有很好的泛化性。

另一方面，人工神经网络的网络结构设计技巧性强、结构多变，需要很大程度上依靠建模经验对电池放电神经网络模型进行吩咐推敲、精心设计。此外，电池放电神经网络模型在误差精度上仍然存在一定缺陷，尤其是在停止电压附近的网络学习效果还需要进一步提升。

## 第五章 总结、展望与致谢

### 1. 总结

本文以电池剩余有效使用时间预测为核心，分别探讨了三种不同情形下的数据驱动数学建模方法。

在稳横放电情形下，提出了综合放电模型和相应的参数估计方法，并通过修正相对预测误差率对模型进行了评价，说明了综合放电模型在稳横放电场景下的准确性。在定额间歇放电情形下，在文献中已经存在的非线性带点模型，提出了基于粒子滤波算法的电池放电模型，进一步扩充电池模型的适用场景范围。最后在变额放电情形下，设计了基于人工神经网络的变额神经网络放电模型，通过网络的学习训练，以及在测试样本下的修正相对误差率对模型进行评价，说明人工神经网络在变电流放电场景下，所提出的电池放电模型具有较好的性能和效果，进一步提升电池模型的应用空间。

通过本课题，笔者讨论和探究了基于数据驱动的数学建模方法，基于不同的实际场景，讨论各种数据驱动方法的特性和使用场景，已解决电池放电剩余有效使用时间预测的最终目标。

### 2. 展望

作为本课题的拓展，我们希望在今后的研究工作中，对更多电流场景下的电池放电模型进行进一步的优化和改进。

一方面，我们希望提高当前问题背景下的预测准确性，进一步降低电池放电模型的修正相对预测误差率。另一方面，我们可以在统一放电过程中预测多次电流变化的剩余有效使用时间问题，并进一步提高模型的泛化性。

### 3. 致谢

光阴荏苒，四年的大学时光转眼走进了尾声。回想刚刚入学时候的稚嫩和大学四年自己所收获的成长，心中感慨，顿生良多感恩之意希望借以毕业论文文末聊以陈说一二。

当得知获得了浙江大学的保送录取之后，没有太多犹豫，我在中科大和浙大之间选择了浙江大学。高中时期的我眼中的浙江大学有着非常亲切的好感，因为当时并没有特别明确的人生规划，而浙江大学是全国首先尝试大类培养方式的学校之一，我相信这是我来到浙江大学的一个重要原因——选择一所注重培养宽知识面、基础扎实人才的高等院校。再次要非常真诚地感谢父亲和母亲一路以来的支持，从我选择浙江大学，到决定出国继续深造，父母都一如既往地支持我、鼓励我，真心希望二位身体健康、有美满愉快的生活。还要特别感谢福州三中计算机竞赛的带头

人魏丽真老师。魏老师在高中三年以来持续不断地支持和栽培，让我有机会在信息学奥林匹克竞赛中取得喜人的成绩，成功报送浙江大学。祝愿魏老师身体健康、桃李满天下。

抱着对大学生活的配好憧憬，我来到了浙江大学，成为了工科试验班（信息）大类的学生，而我的第一个身份——是预科生。

2015年的五月，一个五年来令我最迷恋杭州的月份，我在杭州度过了一段令人难忘的见习生活。在这个月里，我修读了线性代数和大学计算机基础两门课程。大学课堂的初体验丰富而刺激，风雨无阻地早起占座、焦头烂额地挑灯夜战赶作业、热血沸腾的考前复习和出成绩前的焦虑紧张，各种的场景不断出现在眼前，密密地编织着大学的青春回忆。这个月，我认识了大学最重要的朋友——李锡涵。

李锡涵是我在预科阶段的室友，他是一个非常随和但又非常有自己的想法和主见的极客。在预科期间，李锡涵非常专注的从事他在维基百科上的词条编辑工作，我记得当时他正在非常有干劲地写关于雪豹的词条，从外文文献翻译成中文，去医学图书馆查阅动物科学的书籍，我记得我在空闲的时间还帮他做了一大段的翻译。他的计算机知识非常丰富，在当时的我看来简直是电脑小达人，从各种软件知识到入微的硬件细节，我都可以请教他。也正是在那个时候，我有了想要转专业读数学的一部分原因吧。我说李锡涵是我大学时期最重要的朋友是因为他和我共同参加了浙江大学数学建模竞赛。整个比赛中我和他各自发挥自己的专长成功获得了比赛的一等奖，从此也为后来的各种比赛和科研项目打下了合作的基础。

人们说，一个人读大学很重要的是认识良师益友。我想，李锡涵同学一定算是我在大学期间的益友，非常希望借此机会感谢李锡涵同学一直以来的支持、帮助与相互扶持。李锡涵同学将赴北京大学继续学习深造计算机科学，希望他在北京大学能在学术上有进一步的提升，同时也希望能够在今后还有机会一起合作。

在预科之后，我对自己的人生规划有了初步的想法。我想，既然来到了浙江大学，就应该好好把握这里的学习机会，我希望能够在浙江大学打好扎实的基础，为今后的学习做好准备。于是，我决定转专业为数学与应用数学。所以早在新学期开始之前，我就积极关注浙江大学数学科学研究中心（数学中心）所开办的丘成桐数学与应用数学英才班（丘班），并投递了自荐信和报名信息。我想这就是我的本科专业之旅的开始。

很幸运，我在开学之初数学中心进行的面试选拔环节中脱颖而出，成为了12级丘班的学生。虽然在前两个学年中，竺可桢学院对于丘班的行政单位还有一些疏于认可和管理，所幸在班上同学的积极争取下，学校还是本着以培养学生为本的理念，在多方领导的帮助下，12级丘班的行政正式于2014确立了，并在2015的秋冬学期形成了系统的培养方案。再次要特别感谢杨卫和林建华两届校长的热切关注，和陆国栋院长的长期工作和努力。因为有各位校领导的帮助，丘班的学生才能顺利

完成培养计划并成功毕业。在此还要特别感谢数学中心的各位领导和老师的悉心栽培，特别是罗炜老师无微不至的关心和对各种学习生活上的问题的细致解答，希望数学中心的发展越来越红火，丘班越办越好。

在大学二年级期间，我和李锡涵同学在校数学建模竞赛中的良好合作为我们赢得了参加全国比赛的殊荣。在此之际我们邀请安逸宁同学加入我们的队伍，一起征战全国赛。在赛前培训期间，谈之奕老师对我们进行了系统而全面的竞赛指导和模拟练习，极大的提升我整个队伍的数学建模能力和分析技巧，这位我们在全国赛中取得优异的成绩打下了坚实的基础。在此，我希望特别感谢谈之奕老师对我们的教导和信任，是因为谈老师的细致直到，我们才能发挥自己的潜力，为学校争得荣誉。在半年后的全美大学生数学建模竞赛中，谈老师更是帮助我们开辟了良好的参赛环境，并对我们的竞赛状态调整给予了巨大的帮助。谈老师作为工作在一线的杰出教授，对于学生的培养和帮助实属功德无量。此外，朱建新老师作为我的竺可桢学院本科生专业导师，在全国赛前也对我的数学建模论文的写作技巧给予了点评和直到，为我在今后的论文撰写方面提供了一定帮助，因此我希望借此机会也感谢朱老师的帮助。

在浙江大学期间，我参加了浙江省“挑战杯”大学生课外学术与科学研究成果作品竞赛和“民生民意杯”统计调查方案设计大赛，在宋越月、汪雨、夏天一、王翰宸和林炜韬同学的精诚团队合作下，共同取得了优异地成绩。在此希望特别感谢五位同学的相互协作。在大三结束的暑假，我有幸参加了美国加州大学杉矶分校举办的交叉学科暑期科研实习项目，在统计系教授阿米尼的指导下对网络区块挖掘展开了研究，并获得了喜人的项目成果。十分感谢美国加州大学孙教授和整个浙江大学代表团队的每位同学的团结、奋斗和相互鼓励。

竺可桢校长问了每个浙大人的两个问题：“到浙大来做什么？将来毕业后要做什么样的人？”我想我在这四年也常常问自己这个问题。幸运的是，通过四年的大学生活，我心中逐渐有了这两个问题的答案，我希望能够夯实自己的学术基础，投身自己喜欢的行业，奉献自己的一点力量，今后成为行业中的杰出人才。

我在执行自己的毕业设计和撰写自己的毕业论文的大部分时间都是在杭州滴滴出行大数据与机器学习研究院的办公室。利用空余时间和双休日的时间，我在这里获得了大量本课题的研究思路和灵感，感谢滴滴出行的陈瑜庆和冯涛等同事对我的关心与体谅，以及无微不至的关怀与帮助。希望滴滴出行杭州湖畔大数据越来越好，成果越来越丰富！

最后，还要隆重感谢刘康生教授对我毕业论文课题的全程指导和帮助。回想课题形成初期，刘老师带我们参观了南都电源杭州公司，深入了解可课题的研究背景和项目需求，让我对本次毕业设计课题有了全面的了解，并形成了一个初步的规划，这是我成功完成毕业设计的第一步。随后，刘老师多次对我进行了课题研究的指导，每次知道都非常的细致有条理，让我对课题的发展一次次有新的认识和深入

的理解。另外，我还要感谢杨利平老师对我的开题报告和论文的细心审核和修改意见。

## 参考文献

- [1] 谢涛, 曹军威, 高田, 廉小亲, & 董良. (2015). 基于滑动最小二乘算法和电池荷电状态的储能系统平滑控制策略. *电力系统保护与控制*, 43(05), 1-7.
- [2] Coleman, M., Zhu, C. B., Lee, C. K., & Hurley, W. G. (2005). A combined SOC estimation method under varied ambient temperature for a lead-acid battery. *Applied Power Electronics Conference and Exposition, 2005. APEC 2005. Twentieth Annual IEEE (Vol. 2, pp.991-997 Vol. 2)*. IEEE.
- [3] 邓涛, & 孙欢. (2015). 锂离子电池新型 soc 安时积分实时估算方法. *重庆理工大学学报: 自然科学*, 29(1), 101-106.
- [4] Morita, Y., Yamamoto, S., Sun, H. L., & Mizuno, N. (2006). On-Line Detection of State-of-Charge in Lead Acid Battery Using Both Neural Network and On-Line Identification. *IEEE Industrial Electronics, IECON 2006 - 32nd Annual Conference on (pp.3379-3384)*. IEEE.
- [5] Singh, P., & Reisner, D. (2002). Fuzzy Logic-Based State-Of-Health Determination Of Lead Acid Batteries. *Telecommunications Energy Conference, 2002. INTELEC. 24th Annual International (pp.583-590)*.
- [6] 黄文华, 韩晓东, 陈全世, & 林成涛. (2007). 电动汽车 soc 估计算法与电池管理系统的研究. *汽车工程*, 29(03), 198-202.
- [7] Gould, C. R., Bingham, C. M., Stone, D. A., & Bentley, P. (2009). New battery model and state-of-health determination through subspace parameter estimation and state-observer techniques. *Vehicular Technology IEEE Transactions on*, 58(8), 3905 - 3916.
- [8] Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting*, 14(1), 35-62.
- [9] Liu, D., Wang, H., Peng, Y., Xie, W., & Liao, H. (2013). Satellite lithium-ion battery remaining cycle life prediction with novel indirect health indicator extraction. *Energies*, 6(8), 3654-3668.
- [10] Vapnik, V. N. (1995). The nature of statistical learning theory. *Neural Networks IEEE Transactions on*, 10(5), 988 - 999.
- [11] Chen. . Multiple curve fitting with common parameters using nlinfit. *Confidence Interval*.
- [12] 胡士强. (2010). 粒子滤波原理及其应用. 科学出版社.
- [13] Bhangu, B. S., Bentley, P., Stone, D. A., & Bingham, C. M. (2005). Nonlinear observers for predicting state-of-charge and state-of-health of lead-acid batteries for hybrid-electric vehicles. *Vehicular Technology IEEE Transactions on*, 54(3), 783-794.



## 毕业论文（设计）考核

### 一、指导教师对毕业论文（设计）的评语：

指导教师（签名）

年 月 日

### 二、答辩小组对毕业论文（设计）的答辩评语及总评成绩：

成绩比例	文献综述 占（10%）	开题报告 占（20%）	外文翻译 占（10%）	毕业论文（设计） 质量及答辩 占（60%）	总评成绩
分值					

答辩小组负责人（签名）

年 月 日