

国家自然科学基金资助
国家重点研发计划课题资助

Intelligent
Prediction Theory of
Wind Speed along Railways



**铁路沿线大风风速
智能预测理论**

刘 辉 李燕飞 段 铸◎著



人民交通出版社股份有限公司
China Communications Press Co., Ltd.

铁路沿线大风风速智能预测理论

刘 辉 李燕飞 段 铸 著



人民交通出版社股份有限公司
China Communications Press Co., Ltd.

内 容 提 要

本书提出了铁路沿线大风风速智能预测理论及方法。内容分4篇10章。第1篇提供了铁路沿线大风短时预测重要性分析,包括铁路沿线大风风速预测对保障恶劣环境下列车运行安全的影响性和急迫性分析,当前国内外主流铁路沿线大风预警系统的系统构架、预警理论、研发策略和经典算法;第2篇阐述了铁路沿线大风风速时间序列分析预测方法,包括ARIMA模型、滚动时序模型、条件异方差区间模型和季节性模型及其相关的智能混合模型;第3篇构成了铁路沿线大风风速神经网络智能预测方法,包括多层感知器、Elman神经网络、RBF神经网络、ANFIS神经网络、GRNN神经网络等预测模型及其涉及的智能混合模型;第4篇介绍了铁路沿线大风风速智能优化预测方法,包括通过蜻蜓和灰狼算法优化极限学习机和支持向量机预测性能等内容。本书提供了模型预测实例。

本书可供从事交通环境与安全、铁路沿线大风防灾、计算智能和时间序列分析等相关领域的研究学者、博士研究生、高年级硕士研究生和相关部门的管理人员参考使用。

图书在版编目(CIP)数据

铁路沿线大风风速智能预测理论 / 刘辉, 李燕飞,
段铸著. — 北京: 人民交通出版社股份有限公司,
2019.3

ISBN 978-7-114-15175-0

I. ①铁… II. ①刘… ②李… ③段… III. ①铁路沿
线—大风—风速—预测 IV. ①U298

中国版本图书馆CIP数据核字(2018)第269422号

书 名: 铁路沿线大风风速智能预测理论

著 作 者: 刘 辉 李燕飞 段 铸

责任编辑: 郭红蕊 周 凯

责任校对: 赵媛媛

责任印制: 张 凯

出版发行: 人民交通出版社股份有限公司

地 址: (100011)北京市朝阳区安定门外外馆斜街3号

网 址: <http://www.ccpres.com.cn>

销售电话: (010)59757973

总 经 销: 人民交通出版社股份有限公司发行部

经 销: 各地新华书店

印 刷: 北京虎彩文化传播有限公司

开 本: 787×1092 1/16

印 张: 15.75

字 数: 358千

版 次: 2019年3月 第1版

印 次: 2019年3月 第1次印刷

书 号: ISBN 978-7-114-15175-0

定 价: 60.00元

(有印刷、装订质量问题的图书由本公司负责调换)

前 言

大风是危及铁路运输安全的主要自然灾害之一。我国及日本、加拿大、美国等国家均发生过铁路沿线大风所导致的列车被吹翻的重大事故。为降低大风危害,保障人民生命财产的安全,减少由于无法预测沿线大风未来趋势所造成的不必要的列车降速和停运时间,国内外相关机构和科学家都在致力于研建一种融合车-路-大风信息的智能铁路沿线大风预警系统,用于保障极端恶劣大风环境下的列车安全运行,做到大风提前预警。

研究表明,研建这类智能预警系统的关键是实现铁路沿线大风短时预测。如果无法对铁路沿线大风提前预测,也就谈不上当大风来临时对运行列车的提前预警。然而,铁路沿线大风时序数据呈现出极强的非平稳性、随机性和瞬间跳跃性等特点,对它们实现高精度的超前预测难度极大。这涉及交通运输工程、环境科学、计算智能和时间序列分析等多个学科领域,属于国际公认的研究热点和科学难点。

本书总结、提炼了中南大学研究团队数十年的铁路沿线大风预测研究成果。本书的主要思路是将铁路沿线大风预测与人工智能理论的相关前沿成果(如信号分解重构、神经网络多样化建模)相结合,最终提出面向运载列车安全的铁路沿线大风风速智能预测理论与方法。

全书包括4篇,共10个章节。各部分的内容介绍如下:

第1篇:铁路沿线大风短时预测重要性分析。包括铁路沿线大风风速预测对保障恶劣环境下列车运行安全的影响性和紧迫性分析,当前国内外主流铁路沿线大风预警系统的系统构架、预警理论、研发策略和经典算法。实际上,当前基于列车/线路/环境多要素耦合策略所研建的铁路沿线大风预警系统都不具备对铁路沿线大风风速的高精度超前多步预测能力。若没有实现大风预测,这类预警系统就无法耦合预测风速等级,实现列车安全临界速度的超前推演和预警。因此在一定程度上,对铁路沿线大风实现超前短期高精度预测已成为研建下一代智能铁路大风预警系统乃至智慧行车预警系统的卡脖子技术难题。

第2篇:铁路沿线大风风速时间序列分析预测方法。包括ARIMA模型、滚动时序模型、条件异方差区间模型和季节性模型及其相关的智能混合模型。历经数十年,时间序列分析理论已日趋成熟。由于时间序列分析理论拥有建模步骤简单、计算输出实时性好、便于计算显式模型方程等优点,已在电力负荷、交通规划、生物医学等领域得到成功应用。但时间序列分析理论在铁路沿线大风预测的应用才刚刚起步,需要解决大风类别辨识、高精度模型定阶和大步长迭代保持等关键问题。本篇详细阐述了如何基于时间序列理论建立铁路沿线大风风速短时统计预测模型。并提供了本书所提出新预测模型的计算案例。

第3篇:铁路沿线大风风速神经网络智能预测方法。包括多层感知器、Elman神经网络、

RBF 神经网络、ANFIS 神经网络、GRNN 神经网络等预测模型及其相关的智能混合模型。由于神经网络理论拥有较强大的非线性数据处理能力,因此它们在科学和工程各个领域得到了较为广泛的使用。然而,神经网络理论尤其是近年来蓬勃发展的深度神经网络理论在铁路沿线大风预测领域还有巨大的研究潜力和空间,急需解决诸如神经网络输入/输出结构确定随意性、极端跳跃风速难以准确拟合等难题,这些都值得深入研究。本篇详细讨论了如何建立基于多样化神经网络的铁路沿线大风风速短时智能预测模型,并提供了本书所提出新预测模型的计算案例。

第4篇:铁路沿线大风风速智能优化预测方法。包括通过蜻蜓和灰狼算法优化极限学习机和支持向量机的预测性能及其相关的智能优化模型。近年来,各类出色的进化优化算法层出不穷,它们是否适用于大风预测模型的性能优化和精度提升,是值得探索的。需要解决大风分解重构算法、优化算法和大风预测模型之间的数据接口设计。本篇以蜻蜓和灰狼两种新兴的进化算法为例,详细分析了它们对极限学习机和支持向量机两类大风预测模型的优化步骤和优化结果,并提供了所涉及模型的计算案例。

本书的出版和书中的研究成果得到了国家自然科学基金、国家重点研发计划课题、中南大学创新驱动、中南大学升华育英计划等项目的资助,以及来自澳大利亚蒙纳士大学、澳大利亚墨尔本大学、德国罗斯托克大学、中国科学院、北京航空航天大学、西南交通大学、东北财经大学、武汉大学等高校和中国中车、中国铁路总公司等相关单位同行专家的大力指导与帮助,在此表示衷心的感谢。

在本书的撰写过程中,吴海平、陈超、徐一楠、龙治豪、施惠鹏、刘泽宇、陈浩林、董书勤、于程名等团队成员做了大量的模型验证等工作,在此表示由衷的感谢。在本书的出版过程中,得到了人民交通出版社股份有限公司郭红蕊的大力支持,对她的敬业精神和严谨的编辑工作态度敬佩不已,在此表示衷心的感谢。

由于作者的水平有限,书中难免存在缺点和不足之处,恳请各位专家和读者批评指正。

作者 于长沙
2018 年 11 月 10 日

目 录

第 1 篇 铁路沿线大风短时预测重要性分析

第 1 章 绪论	3
1.1 背景	3
1.2 铁路沿线大风预测预警系统	4
1.3 铁路沿线大风风速预测理论基础	4
1.4 铁路沿线大风风速预测方法体系	7
1.5 铁路沿线大风风速预测经典算法	11

第 2 篇 铁路沿线大风风速时间序列分析预测方法

第 2 章 铁路沿线大风风速 ARIMA 预测模型	25
2.1 引言	25
2.2 原始风速序列	25
2.3 铁路沿线大风风速 ARIMA 预测模型	26
2.4 铁路沿线大风风速滚动 ARIMA 预测模型	33
2.5 铁路沿线大风风速分解-滚动 ARIMA 预测模型	35
2.6 模型预测精度综合对比分析	42
2.7 总结	45
第 3 章 铁路沿线大风风速条件异方差区间预测模型	47
3.1 引言	47
3.2 区间预测	48
3.3 原始风速序列	49
3.4 铁路沿线大风风速条件异方差区间预测模型	49
3.5 铁路沿线大风风速经验小波分解-条件异方差区间预测模型	59
3.6 模型预测精度综合对比分析	68
3.7 总结	70
第 4 章 铁路沿线大风风速季节效应预测模型	71
4.1 引言	71
4.2 原始风速序列	72
4.3 铁路沿线大风风速非季节性预测模型	73

4.4	铁路沿线大风风速季节性预测模型	78
4.5	模型预测精度综合对比分析	84
4.6	总结	90
 第3篇 铁路沿线大风风速神经网络智能预测方法		
第5章	铁路沿线大风风速多层感知器预测模型	93
5.1	引言	93
5.2	原始风速序列	94
5.3	铁路沿线大风风速集成经验模态分解-多层感知器预测模型	96
5.4	铁路沿线大风风速小波分解-多层感知器预测模型	100
5.5	铁路沿线大风风速集成经验模态分解-小波分解-多层感知器预测模型	102
5.6	模型预测精度综合对比分析	105
5.7	总结	110
第6章	铁路沿线大风风速 Elman 神经网络预测模型	112
6.1	引言	112
6.2	原始风速序列	113
6.3	铁路沿线大风风速 Elman 神经网络预测模型	115
6.4	铁路沿线大风风速小波包分解-Elman 神经网络预测模型	118
6.5	模型预测精度综合对比分析	124
6.6	总结	136
第7章	铁路沿线大风风速 RBF 神经网络预测模型	137
7.1	引言	137
7.2	原始风速序列	138
7.3	铁路沿线大风风速小波包分解-RBF 神经网络预测模型	139
7.4	铁路沿线大风风速小波包分解-RBF 神经网络-GRNN 误差修正预测模型	145
7.5	铁路沿线大风风速小波包分解-RBF 神经网络-WF 误差修正预测模型	150
7.6	铁路沿线大风风速 Hampel identifier 异常值检测-小波包分解-RBF 神经网络预测模型	155
7.7	铁路沿线大风风速 Hampel identifier 异常检测-小波包分解-RBF 神经网络-GRNN 误差修正预测模型	159
7.8	预测模型预测精度综合对比分析	159
7.9	总结	162
第8章	铁路沿线大风风速 ANFIS 预测模型	163
8.1	引言	163
8.2	原始风速序列	164
8.3	铁路沿线大风风速分解算法-ANFIS 预测模型	165
8.4	铁路沿线大风风速二次分解-ANFIS 预测模型	170
8.5	铁路沿线大风风速三次分解-ANFIS 预测模型	179

8.6	预测模型预测精度综合对比分析	187
8.7	总结	190
第4篇 铁路沿线大风风速智能优化预测方法		
第9章	铁路沿线大风风速极限学习机优化预测模型	193
9.1	引言	193
9.2	原始风速序列	193
9.3	铁路沿线大风风速极限学习机预测模型	194
9.4	铁路沿线大风风速小波包分解-极限学习机预测模型	196
9.5	铁路沿线大风风速小波包分解-蜻蜓算法-极限学习机预测模型	197
9.6	模型预测精度综合对比分析	200
9.7	总结	206
第10章	铁路沿线大风风速支持向量机优化预测模型	207
10.1	引言	207
10.2	原始风速序列	208
10.3	铁路沿线大风风速支持向量机预测模型	209
10.4	铁路沿线大风风速经验小波分解-支持向量机预测模型	212
10.5	铁路沿线大风风速经验小波分解-灰狼算法-支持向量机预测模型	215
10.6	预测模型预测精度综合对比分析	218
10.7	总结	226
参考文献		227

第1篇

铁路沿线大风短时预测 重要性分析

本篇介绍了铁路沿线大风预测相关研究进展以及经典算法。铁路沿线大风会破坏铁路列车的侧向稳定性,给铁路列车运行安全带来了隐患。我国兰新铁路、青藏铁路等铁路饱受强风灾害影响,因此对铁路沿线大风预测算法的研究迫在眉睫。

第1章阐述了铁路沿线大风预测研究的必要性,介绍了各国铁路运营部门采取的铁路沿线大风预警系统原理。使用了威布尔分布、瑞利分布等五种不同概率分布研究了铁路沿线大风的统计特征。总结归纳了已有铁路沿线大风预测算法理论研究成果,从物理模型、统计模型、智能模型和混合模型四个方面介绍了研究进展。介绍了小波分解、小波包分解等八种铁路沿线大风预测常用的分解算法,提供了两种经典的铁路沿线大风多步预测结构策略,介绍了面向点预测以及区间预测的多种铁路沿线大风预测算法精度评价指标。

本篇结合国内外参考文献提供的铁路沿线大风预测研究的基本概况以及典型算法理论,可以为铁路风速预测算法的后续研究指引方向,是本书后续理论算法研究的基础。



第1章 绪论

1.1 背景

近年来,中国铁路的发展取得了举世瞩目的成就。为了更好地切合国家实际情况以服务于国家重大战略,国家发展和改革委员会于2014年对2004年版的《中长期铁路网规划》进行修编,在广泛征求社会各方面意见的基础上,国家发展和改革委员会、交通运输部和铁路总公司于2016年7月13日正式印发《中长期铁路网规划》(发改基础〔2016〕1536号)。其中提出,到2020年全国铁路营业总里程达到15万km,高速铁路里程达到3万km,构建出“八纵八横”的高速铁路主通道。到2025年,我国高速铁路总里程将达到3.8万km左右,预计“十三五”期间以客运专线为主体的铁路建设投资将达3.5万亿元。

我国幅员辽阔,南北跨度大,气候多样,因此对铁路的适应性以及安全性要求较高。在众多恶劣气候中,强风对于高速列车的影响不容忽视。包括中国、德国、英国、日本等在内的众多国家,都针对恶劣大风对列车的行车安全影响展开了一系列研究。研究表明:在横强风作用下,列车的侧向稳定性会急剧恶化,当列车自身的稳定力矩小于大风造成的倾覆力矩时,列车有可能发生倾覆^[1]。对于一些特殊路况,如特大桥梁、曲线路段以及山区风口区域等,列车的绕流流场突变更为突出,对列车运行安全的影响也更为明显。此外,大风会导致电力机车的受电弓与接触网之间接触不良,进而降低列车受流质量^[2]。

在日本,由强风导致的列车倾覆事故屡屡发生。1986年,由于大风的影响,一列内燃列车在日本余部桥处倾覆并坠至桥下,导致6人死亡、6人受伤以及道路桥梁设施受损^[3]。在我国的强风路段,大风是众多列车脱轨、倾覆事故的直接原因,严重影响了铁路的运行安全。2007年2月28日2时5分,受到十三级大风的影响,由乌鲁木齐开往阿克苏的5807次列车在我国南疆铁路珍珠泉至红山渠区间段发生脱轨事故,导致3人死亡、34人受伤、铁路停运9h的严重后果。该事故是中华人民共和国成立以来最严重的一起由大风造成的客运列车倾覆事故^[4]。

兰新铁路以及青藏铁路是我国强风灾害较为严重的两条线路。兰新铁路途经的“百里风区”“三十里风口”“达坂城风区”多为人迹罕至的戈壁滩,是世界内陆风力最强的地区,每年大风天数超过160天,有记录的历史最高风速可达64m/s,最大风力等级超过17级^[5-6]。作为全球海拔最高的铁路,青藏铁路同样长期受到强风的侵害。在青藏铁路途经的青藏高原大风中心区域,每年大风天数超过100天,有记录的历史最高风速可达40m/s。兰新铁路以及青藏铁路沿线的大风灾害给铁路运行安全带来了隐患^[7]。

在这种恶劣的环境下,以实时的风速数据作为预警调度信息给铁路运行安全带来了一定的帮助,但是具有一定的局限性。例如,铁路管理部门只考虑实时风速数据,当列车所在



区域突发强风灾害时,预警系统将会命令列车减速或停车。在强风灾害消除后,为了进一步保证列车运行安全,铁路预警系统会命令列车保持减速或停车状态,降低了列车的运行效率。

随着目前人工智能以及大数据技术的逐渐发展,精确的高实时性风速预测成为可能。如果系统具备沿线各测风站超前预测功能,调度部门则可以根据系统预测预报风速作出限速或解禁决定,为列车争取了安全时间,也提高了决策可靠度。因此,铁路沿线风速预测研究具有重要的工程现实意义。

1.2 铁路沿线大风预测预警系统

德国国家铁路公司(Deutsche Bahn AG,DB)为了应对铁路运行过程中的强风灾害,开发了一套能够实现超前两分钟预测的铁路强风监测预警系统 Nowcasting System^[9]。该系统能够根据沿线测风站以及车辆、路段信息,将每一台车辆的行驶速度最大值反馈到每一台车辆的列车控制系统中。其中,风速预测结果使用外推平均风速、外推误差、外推标准差的线性组合得到,有效性为 20s。

东日本铁路公司(JR-EAST)开发了一套强风列车预警系统(Windas System)。该系统使用卡尔曼滤波,实现了超前 12 步(36min)预测^[8]。该预警系统的原理与 Nowcasting System 原理类似,同样通过采集铁路沿线实时风速、车辆状况以及道路状况等信息,进而得到各列车的运行速度最大值。其中需要注意的是,东日本铁路公司使用 Labview 语言以及 NTT DoCoMo 无线协议自主开发了一套用于实时调度控制的无线通信模块。

国内目前的铁路强风灾害预警系统以检测预警为主^[10],可以实时采集风向、风速等信息,再结合历史风速信息、地理信息、车辆情况分析风—路—车耦合模型,进而得到行车速度最大值。这类系统在我国兰新铁路以及青藏铁路都得到了应用。

1.3 铁路沿线大风风速预测理论基础

1.3.1 铁路沿线大风风速短时预测步长

铁路沿线风速序列通常采集自铁路沿线的各测风站,它们具有极强的随机性、间歇性以及波动性。根据预测风速的时间间隔,风速预测可以分为如下 4 种^[11]:

- (1)超短期预测:预测时间为超前几秒到 30min。
- (2)短期预测:预测时间为超前 30min 到 6h。
- (3)中期预测:预测时间为超前 6h 到 1 天。
- (4)长期预测:预测时间为超前 1 天到 1 周。

预测时间越短,提供的信息越精细,但是留给铁路部门调控的时间也会随之缩短;而预测时间越长,则能够提供更长期的风速信息,但通常精度较差,无法短期内精细化风速信息。针对面向列车运营安全的铁路沿线风速预测而言,最关键的是超短期以及短期风速预测。



1.3.2 铁路沿线大风风速序列统计特征

在风速预测领域,通常使用威布尔(Weibull)分布、瑞利(Rayleigh)分布、对数正态(Lognormal)分布、伽马(Gamma)分布以及 Burr 分布来拟合风速序列的分布^[12]。本书采用6个不同的风速序列来证明各分布的拟合精度,每个风速序列时间间隔均为 3min。各个分布的具体公式如下所示^[13]。

(1) 威布尔分布

威布尔分布是风速分布拟合中最常用的模型,能够适用于具有偏度以及没有偏度的分布。其概率密度函数为:

$$f(v) = \frac{k}{c} \left(\frac{v}{c} \right)^{k-1} \exp \left(- \left(\frac{v}{c} \right)^k \right) \quad (1.1)$$

式中, k 为形状参数; c 为尺度参数。若风速数据的方差较小,则 k 值较大,分布曲线呈现出尖峰厚尾的特点。当 $k=1$ 时,威布尔分布退化为指数分布,当 $k=2$ 时,威布尔分布退化为瑞利分布,当 $k=3.5$ 时,威布尔分布与正态分布十分接近。 c 代表平均风速,当 $c=1$ 时,称分布为威布尔分布。威布尔分布的期望以及方差分别为:

$$\mu = c \Gamma(1 + 1/k) \quad (1.2)$$

$$\sigma^2 = c^2 \Gamma(1 + 2/k) - \mu^2 \quad (1.3)$$

(2) 瑞利分布

瑞利分布为威布尔分布取 $k=2$ 时的特例,其待估参数只剩下尺度参数 c , 概率密度函数以及方差、均值等统计特征可以根据威布尔分布的各统计特征计算得出。Corotis 等^[14]通过实验说明瑞利分布相比于威布尔分布能够更加有效地拟合风速分布。

(3) 对数正态分布

对数正态分布是正态分布的一个变种,其概率密度函数为:

$$f(v) = \frac{1}{vk\sqrt{2\pi}} \exp \left(\frac{-(\ln v - c)^2}{2k^2} \right) \quad (1.4)$$

式中, c 为变量 v 的对数均值; k 为变量 v 的对数标准差。对数正态分布的数学期望以及方差分别为:

$$\mu = \exp \left(c + \frac{k^2}{2} \right) \quad (1.5)$$

$$\sigma^2 = \exp(2c + k^2) (\exp(k^2) - 1) \quad (1.6)$$

(4) 伽马分布

伽马分布是一种最早用于风速分布拟合的模型,其概率密度函数为:

$$f(v) = \frac{v^{k-1}}{c^k \Gamma(k)} \exp \left(- \frac{v}{c} \right) \quad (1.7)$$

式中, k 为形状参数; c 为尺度参数。伽马分布的期望以及方差分别为:

$$\mu = ck \quad (1.8)$$

$$\sigma^2 = c^2 k \quad (1.9)$$

(5) Burr 分布

Burr 分布的计算量比较大,但是通常具有较好的拟合效果^[15]。其概率密度函数为:



$$f(v) = \frac{\alpha k \left(\frac{v}{\beta}\right)^{\alpha-1}}{\beta \left(1 + \left(\frac{v}{\beta}\right)^{\alpha}\right)^{k+1}} \quad (1.10)$$

式中, α 为形状参数; β 和 k 为尺度参数。Burr 分布的期望以及方差分别为:

$$\mu = \frac{\beta \Gamma\left(1 + \frac{1}{\alpha}\right) \Gamma\left(k - \frac{1}{\alpha}\right)}{\Gamma(k)} \quad (1.11)$$

$$\sigma^2 = \beta^2 \left(\frac{\Gamma\left(1 + \frac{1}{\alpha}\right) \Gamma\left(k - \frac{2}{\alpha}\right)}{\Gamma(k)} - \mu^2 \right) \quad (1.12)$$

(6) 统计案例分析

使用 6 组我国某强风铁路沿线实测的大风风速数据, 对以上 5 种分布模型进行统计和拟合分析, 采用极大似然估计方法完成各类所建模型的参数估计计算。各大风时间序列的统计特征如表 1-1 所示。从以上统计量可知: 风速的偏度大于 0, 呈偏态分布, 即风速较低的概率要高于风速较高的概率; 风速的峰度小于 0, 呈平顶峰分布。

各序列的统计特征

表 1-1

项 目	均值 (m/s)	标准差 (m/s)	最小值 (m/s)	最大值 (m/s)	偏度	峰度
序列 1	5.2426	1.9711	0.8000	12.3000	0.4420	-0.2922
序列 2	15.3901	3.5249	6.8000	25.6000	0.1447	-0.5083
序列 3	20.0764	3.4694	10.9000	30.5000	0.0561	-0.3978
序列 4	14.3155	3.5552	4.4000	24.4000	0.0019	-0.2919
序列 5	7.3737	2.1829	2.3000	14.5000	0.1054	-0.4063
序列 6	18.4986	3.5567	10.5000	28.7000	0.1921	-0.3718

各序列拟合后的负对数似然函数值如表 1-2 所示。以序列 2 为例, 各个概率分布的拟合结果如图 1-1 所示。从以上图表中可知, 瑞利分布拟合效果最差, 由于该模型只有一个参数可调, 高估了实际分布的偏度, 因此导致拟合效果较差。在其他分布中, 伽马分布以及 Burr 分布的拟合效果最优。

各序列拟合后的负对数似然函数值 (单位: $\times 10^3$)

表 1-2

项 目	威布尔分布	瑞利分布	对数正态分布	伽马分布	Burr 分布
序列 1	1.0784	1.1271	1.0859	1.0745	1.0768
序列 2	1.3866	1.6094	1.3880	1.3818	1.3840
序列 3	1.3882	1.7359	1.3856	1.3810	1.3827
序列 4	1.3870	1.5799	1.4106	1.3964	1.3861
序列 5	1.1416	1.2674	1.1646	1.1496	1.1412
序列 6	1.3845	1.6759	1.3744	1.3711	1.3763




图 1-1 序列 2 的概率分布拟合结果

1.4 铁路沿线大风风速预测方法体系

由于风速时间序列具有极强的随机性和波动性,如何实现对其进行精准有效的预测已成为众多学者的研究热点。近年来提出了大量的风速预测模型,可分为物理方法、统计方法、智能方法和混合方法^[16-18]。



1.4.1 物理方法

物理方法考虑风速成因(如温度、气压、海拔等信息),使用气象学科预报模型对风速的变化趋势进行模拟计算,进而实现风速预测。常见方法包括数值天气预报(NWP)、空间相关方法等。除此之外,还有一些改进的物理方法。CASSOLA 等人^[19]使用卡尔曼滤波器来校正数值天气预报的预测误差,卡尔曼滤波器用于最小化预测误差。ZHAO 等人^[20]提出了一种新的风速预测模型,该模型被称为杜鹃搜索-模糊系统-WRF 集成(CS-FS-WRF-E)模型^[20]。该模型由布谷鸟搜索(Cuckoo Search, CS)、天气研究和预报(Weather Research Forecasting, WRF)和模糊系统(Fuzzy System, FS)组成。由于延迟问题,物理模型在 0~2h 预测时间内的实用价值有限。从初始时间生成预测可能需要 1~2h。然而,在天气情况变化较为显著时,NWP 模型可以代表可能导致风坡的天气现象,如锋面和雪景。与单独的方法相比,NWP 模型与后处理相结合可以产生更好的预测。

1.4.2 统计方法

统计方法在风速预测中也得到了广泛的应用。该方法运用数理统计的方法描述风速的演变规律,进而来进行预测。包括差分自回归移动平均模型(AutoRegressive Integrated Moving Average, ARIMA)、自回归条件异方差模型(Autoregressive conditional heteroscedasticity model, ARCH)、卡尔曼滤波(Kalman Filter, KF)等等。其中最具代表性的是 ARIMA 模型。

经典的 ARIMA 模型描述了时间序列随时间的相关性,在金融^[22]、机械故障诊断^[23]、气象科学^[24]等领域取得了成功的应用。为了进一步提高传统 ARIMA 方法的预测性能,国内外学者在经典方法的基础上,提出了新型的统计方法来进行风速预测。YUAN 等人^[25]提出了滚动时域 ARIMA 模型,以实现圣维森特风场的准确风速预测。El-FOULY^[26]等人利用当前风速与前一年和前两年的风速之间的关系提出两种模型,称为一年模型和两年模型。此研究验证了所提出的模型的有效性。文献[27]也验证了一年模型和两年模型的准确性。KIPLANGAT 等人^[28]将自回归(Auto-Regressive, AR)模型与分数部分差分自回归移动平均(fractional-Auto-Regressive Moving Average, f-ARIMA)模型进行了对比。MASSERAN^[29]将 ARIMA 与 ARCH 结合应用于风速预测。结果表明,ARIMA-ARCH 比 ARIMA 方法具有更好的风速预测性能。WANG 等人^[30]使用粒子群算法(Particle Swarm Optimization, PSO)优化的傅立叶模型来拟合季节性自回归移动平均模型(Seasonal ARIMA, S-ARIMA)的残差。结果表明,所提出的模型性能要优于粒子群优化的最优傅立叶方法和 ARIMA 模型。

卡尔曼滤波由鲁道夫·卡尔曼提出,是一种经典的系统状态估计模型^[31]。ZULUAGA 等人^[32]使用三种方法提高卡尔曼滤波器的稳健性。三个改进的卡尔曼滤波器分别为加权鲁棒卡尔曼滤波器(weighted robust Kalman Filter, wrKF)、稳健统计卡尔曼滤波器(robust statistics Kalman Filter, rsKF)和阈值卡尔曼滤波器(thresholded Kalman Filter, tKF)。研究表明,加权鲁棒卡尔曼滤波器和稳健统计卡尔曼滤波器要优于阈值卡尔曼滤波器和传统的卡尔曼滤波器。LIU 等人^[33]使用 ARMA 确定 KF 模型的初始参数。

除了以上两种经典的统计方法之外,贝叶斯模型以及灰度模型在风速预测领域也有很多应用。MIRANDA 等人^[34]使用贝叶斯模型实现了对于风速的超前一小时预测。



ZAPHIROPOULOS等人^[35]以及 EL-FOULY 等人^[36]使用灰度模型实现了对风速的精准预测。

统计方法在短期风速预测中具有良好的性能,但处理非线性数据的能力不足^[37],拟合能力有限。在高预测步数的情况下统计方法有明显的时延情况。SAMET 等人^[38]提出了一种新的指标来量化利用非线性确定性分量预测的性能。结果表明,具有外源项的自回归移动平均模型只能预测风速的线性部分。

1.4.3 智能方法

智能方法的建模目标是风速的统计演变规律。与统计方法相比,智能算法具有更强的鲁棒性以及泛化性,能够描述复杂风速序列的内在非线性关系,在风速的超前多步预测中表现更好。^[39]。在目前的风速预测研究中,被广泛研究并使用的智能算法包括神经网络、深度神经网络以及算成算法。

神经网络(Artificial Neuron Network, ANN)在解决复杂和非线性问题方面有更好的性能,广泛应用于科学、商业和工程等领域^[40-42]。神经网络模型包括多层感知器(Multi Layer Perceptron, MLP)、循环神经网络(Recurrent Neuron Network, RNN)和径向基神经网络(Radial Basis Function Neuron Network, RBFNN)等。已有众多研究结果表明,智能方法可获得更好的预测性能,在风速预测领域已有较好的应用。例如,AGRAWAL 等人^[43]提出了一种新的模型,即基于自回归的人工神经网络模型(Artificial Neural Network based Yearly Auto-Regressive, ANNYAR)。该模型使用过去几年的风速数据和其他数值天气预报参数来预测风速。此研究表明了所提模型具有优异的预测性能。AGRAWAL 等人^[44]比较了几种风速预测模型,发现小波变换技术和人工神经网络由于其良好的非线性拟合能力而优于其他模型。DONG 等人^[45]提出了一种利用人工神经网络预测风速的有效方法,利用导引寻优算法优化的局部线性模糊神经网络预测风速。杨秀媛等^[46]使用滚动更新参数的神经网络对风速进行预测,并将预测结果与时间序列模型对比。结果表明,神经网络得到比传统时间序列模型更高的预测精度。SALCEDO-SANZ 等人^[47]提出了一种基于珊瑚礁优化算法(Coral Reefs Optimization Algorithm, CRO)的极限学习机模型(Extreme Learning Machine, ELM)。HONG^[48]提出了一种使用同步扰动随机逼近算法(Simultaneous Perturbation Stochastic Approximation, SPSA)训练多层前馈网络(Multi-layer Feed-forward Neural Network, MFNN)的预测算法。

深度神经网络在传统神经网络的基础上发展而来。深度神经网络具有更多、更复杂的网络结构,具有更强的非线性映射能力^[49]。在风速预测领域常用的深度神经网络包括卷积神经网络(Convolutional Neuron Network, CNN)以及长短期记忆网络(Long Short Term Memory, LSTM)等。WANG 等人^[50]提出了一种基于小波分解以及卷积神经网络的风速预测方法,通过实验证明,这种预测方法的精度相比于传统的多层感知机、支持向量机等模型有很大的提升。LIU 等人^[51]提出了一种基于卷积神经网络以及卷积长短期记忆神经网络的一种新型风速预测方法,通过实验说明了这种算法相比于小波包分解-多层感知机、小波包分解-极限学习机等模型具有更好的性能。

除神经网络之外,集成方法也是机器学习中的一个重要研究方向。集成方法可以通过组合性能较弱的基预测器,将其加权结合并形成一个强预测器,以提高混合模型的预测性