

## 基于快速极限学习机和差分进化的机场噪声预测模型

徐涛<sup>①②</sup> 郭威<sup>\*②③</sup> 吕宗磊<sup>①</sup>

<sup>①</sup>(中国民航大学计算机科学与技术学院 天津 300300)

<sup>②</sup>(南京航空航天大学计算机科学与技术学院 南京 210016)

<sup>③</sup>(盐城师范学院信息工程学院 盐城 224002)

**摘要:** 该文针对传统机场噪声预测模型存在的建模成本高、实用性差的不足,引入时间序列相空间重构理论,提出一种新的基于快速极限学习机和差分进化算法的机场噪声一体化预测模型。该模型利用相空间重构理论对机场噪声时间序列进行重构,并使用快速极限学习机对重构的相空间向量进行学习建模,同时采用改进的差分进化算法实现对重构参数和模型参数的同步优化选择,整个建模过程简洁高效,无需人工干预。实验结果表明,该一体化预测模型能较好地跟踪机场噪声的变化趋势,且具有较同类模型更小的预测误差。

**关键词:** 机场噪声预测;快速极限学习机;差分进化;相空间重构

中图分类号: TP391

文献标识码: A

文章编号: 1009-5896(2016)06-1512-07

DOI: 10.11999/JEIT150986

## Prediction Model of Airport Noise Based on Fast Extreme Learning Machine and Differential Evolution

XU Tao<sup>①②</sup> GUO Wei<sup>\*②③</sup> LÜ Zonglei<sup>①</sup>

<sup>①</sup>(College of Computer Science and Technology, Civil Aviation University of China, Tianjin 300300, China)

<sup>②</sup>(College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

<sup>③</sup>(College of Information Engineering, Yancheng Teachers University, Yancheng 224002, China)

**Abstract:** Traditional airport noise prediction models are insufficient for their high modeling cost and poor practicability. In this paper, the time series phase space reconstruction theory is introduced, and a novel integrated airport noise prediction model based on fast extreme learning machine and differential evolution is proposed. In the proposed model, the airport noise time series is reconstructed based on the phase space reconstruction theory, and the fast extreme learning machine is used to model the reconstructed phase space vector. Meanwhile, an improved differential evolution algorithm is adopted to search for the optimal parameter combination of phase space reconstruction parameter and model parameter simultaneously. The whole modeling process of the integrated prediction model is very simple and efficient without any manual intervention. Experimental results demonstrate that the proposed model can track the variation tendency of airport noise well and can achieve much more accurate prediction results than its counterparts.

**Key words:** Airport noise prediction; Fast extreme learning machine; Differential evolution; Phase space reconstruction

### 1 引言

近年来,中国民航业持续快速发展。但是,不

断新建、扩建的机场和持续增长的航空运输量也使得困扰民航业已久的机场噪声问题愈发严重,由此而产生的噪声污染对环境的影响日益加剧,并成为影响中国民航持续健康发展的障碍之一<sup>[1-3]</sup>。机场噪声预测能够为控制噪声影响,优化机场周边环境提供决策支持和依据,因此,构建准确高效的机场噪声预测模型具有非常重要的实用价值。

目前,传统的机场噪声预测研究主要集中于根据噪声影响因素建立噪声计算的数学模型,从而实现对机场噪声的预测<sup>[4-6]</sup>,其中应用最为广泛的是美国联邦航空管理局提出的集成噪声模型 INM,以及美国国防部和美国国家航空航天局为美国军用机场研发的噪声预测模型 NOISEMAP 等。这些模型以

收稿日期: 2015-09-06; 改回日期: 2016-01-20; 网络出版: 2016-03-14

\*通信作者: 郭威 weiguo031@163.com

基金项目: 国家自然科学基金重点项目(61139002), 国家科技支撑计划课题(2014BAJ04B02), 中央高校基本科研业务费专项资金(3122014D032), 中国民航信息技术科研基地开放基金课题(CAAC-ITRB-201401)

Foundation Items: The Key Program of the National Natural Science Foundation of China (61139002), The National Key Technology Research and Development Program of the Ministry of Science and Technology of China (2014BAJ04B02), The Fundamental Research Funds for the Central Universities of Ministry of Education of China (3122014D032), The Open Project Foundation of Information Technology Research Base of Civil Aviation Administration of China (CAAC-ITRB-201401)

预测点到飞机航迹的距离为核心,通过对飞机既有基本声学数据插值来计算预测点的噪声级,并在此基础上使用噪声影响因素对模型进行修正,从而得到与特定机场相符的噪声预测模型。但这类预测模型需要数目庞杂且精度要求很高的输入参数,如飞机的飞行属性、航班信息数据、气象条件数据、机场地形地貌数据等,然而在现实环境中要全面准确地获取到这些实际参数不仅成本很高而且参数质量难以保证,从而导致模型预测精度不高、实用性较差等问题<sup>[7,8]</sup>。

为了克服传统机场噪声预测模型存在的不足,本文从时间序列预测的角度出发,对机场历史噪声数据进行重建建模,提出一种基于快速极限学习机(Fast Extreme Learning Machine, FELM)和差分进化(Differential Evolution, DE)<sup>[9]</sup>的机场噪声一体化预测模型。该模型首先利用相空间重构理论对机场噪声时间序列数据进行重构,然后使用 FELM 算法对重构的相空间矢量进行学习拟合以建立机场噪声预测模型,并采用改进的 DE 算法来同步选择相空间重构参数和 FELM 的模型参数。与传统机场噪声预测模型相比,该一体化预测模型完全基于历史监测数据而构建,不仅建模成本低,建模过程简单高效,而且具有良好的预测效果。

## 2 快速极限学习机

快速极限学习机是一种改进的极限学习机算法,在本文中用来对机场噪声时间序列进行建模。本节首先介绍了极限学习机的基本理论,在此基础上提出了一种计算效率更高的快速极限学习机算法。

### 2.1 极限学习机

极限学习机(Extreme Learning Machine, ELM)<sup>[10]</sup>是一种针对单隐层前馈神经网络(SLFNs)的新兴机器学习算法。对于  $N$  个任意的相异样本  $(\mathbf{x}_j, \mathbf{t}_j) \in \mathbf{R}^d \times \mathbf{R}^m$ , 具有  $n$  个隐层节点的 SLFNs 的数学模型为

$$\sum_{i=1}^n \beta_i g_i(\mathbf{x}_j) = \sum_{i=1}^n \beta_i G(\mathbf{a}_i, b_i, \mathbf{x}_j), \quad j = 1, 2, \dots, N \quad (1)$$

式中,  $\mathbf{a}_i$  和  $b_i$  分别是第  $i$  个隐层节点的输入权值向量和偏置,  $\beta_i$  是连接第  $i$  个隐层节点与输出层的输出权值向量,  $g_i(\mathbf{x}_j) = G(\mathbf{a}_i, b_i, \mathbf{x}_j)$  表示第  $i$  个隐节点关于输入向量  $\mathbf{x}_j$  的输出。

该 SLFNs 能以零误差逼近这  $N$  个样本意味着存在  $(\mathbf{a}_i, b_i)$  及  $\beta_i$  使得

$$\sum_{i=1}^n \beta_i G(\mathbf{a}_i, b_i, \mathbf{x}_j) = \mathbf{t}_j, \quad j = 1, 2, \dots, N \quad (2)$$

式(2)  $N$  个等式可写成式(3)矩阵形式:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (3)$$

其中

$$\mathbf{H} = \begin{bmatrix} \mathbf{h}(\mathbf{x}_1) \\ \mathbf{h}(\mathbf{x}_2) \\ \vdots \\ \mathbf{h}(\mathbf{x}_N) \end{bmatrix} = \begin{bmatrix} G(\mathbf{a}_1, b_1, \mathbf{x}_1) & G(\mathbf{a}_2, b_2, \mathbf{x}_1) & \cdots & G(\mathbf{a}_n, b_n, \mathbf{x}_1) \\ G(\mathbf{a}_1, b_1, \mathbf{x}_2) & G(\mathbf{a}_2, b_2, \mathbf{x}_2) & \cdots & G(\mathbf{a}_n, b_n, \mathbf{x}_2) \\ \vdots & \cdots & \ddots & \vdots \\ G(\mathbf{a}_1, b_1, \mathbf{x}_N) & G(\mathbf{a}_2, b_2, \mathbf{x}_N) & \cdots & G(\mathbf{a}_n, b_n, \mathbf{x}_N) \end{bmatrix}_{N \times n} \quad (4)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \beta_2^T \\ \vdots \\ \beta_n^T \end{bmatrix}_{n \times m}, \quad \mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \mathbf{t}_2^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix}_{N \times m} \quad (5)$$

根据文献[10]中的插值理论,给定一个 SLFNs 和  $N$  个任意不同样本,只要隐层激活函数无限可微,隐层节点参数  $(\mathbf{a}_i, b_i)$  可随机赋值并保持不变,此时  $\mathbf{H}$  为一常数矩阵,则 SLFNs 的训练就转化为求解线性系统  $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$  的最小二乘解  $\hat{\boldsymbol{\beta}}$ :

$$\|\mathbf{H}\hat{\boldsymbol{\beta}} - \mathbf{T}\| = \min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{T}\| \quad (6)$$

ELM 采用最小模最小二乘解作为网络的输出权值,即:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^\dagger \mathbf{T} \quad (7)$$

式中,  $\mathbf{H}^\dagger$  为  $\mathbf{H}$  的 Moore-Penrose 广义逆。 $\mathbf{H}^\dagger$  的计算可用不同的方法进行求解,其中奇异值分解(Singular Value Decomposition, SVD)作为一种通用方法而被广泛使用。

有别于传统基于梯度下降的学习算法,ELM 无需迭代调整参数,整个学习过程一次完成,因而能达到极快的学习速度;此外,ELM 实现简单,唯一需要人为确定的参数只有隐层节点个数;研究表明,ELM 不仅学习速度快,训练参数少,而且还具有比其他流行算法更好的泛化能力。鉴于 ELM 诸多优良特性,本文引入 ELM 算法来对机场噪声时间序列进行建模。

### 2.2 快速极限学习机

尽管 ELM 算法通过避免繁琐的迭代学习步骤而极大地减少了训练时间,事实上,ELM 的学习速度可进一步提高。如 2.1 节所述,ELM 的核心在于求解线性系统  $\mathbf{H}\boldsymbol{\beta} = \mathbf{T}$  的最小二乘解,普通的 ELM 算法通常使用 SVD 方法计算  $\mathbf{H}^\dagger$  而得到最小模最小

二乘解作为输出权值:

$$\hat{\beta} = \mathbf{H}^\dagger \mathbf{T} = (\mathbf{U}\Sigma\mathbf{V}^\top)^\dagger \mathbf{T} = \mathbf{V}\Sigma^\dagger\mathbf{U}^\top\mathbf{T} \quad (8)$$

式中  $\mathbf{U}, \mathbf{V}$  为正交矩阵,  $\Sigma$  为对角矩阵。虽然 SVD 是一个普遍适用且数值稳定的矩阵分解方法, 但它存在一个明显的缺点: 计算复杂度高。特别是当矩阵维度较高时, 其计算效率将显著下降。完全正交分解(Complete Orthogonal Decomposition, COD)是求解线性最小二乘问题的一种替代方法, 与 SVD 相比, COD 计算复杂度较低且具有同样的计算可靠性和稳定性<sup>[11,12]</sup>。为了进一步提高 ELM 的计算效率, 本小节以 COD 为基础推导出一种简化的 COD 表示方法, 并使用该方法来计算 ELM 的输出权值, 提出一种计算效率更高的快速 ELM 算法。

首先, 我们给出 COD 的定义。

**定义** 设  $\mathbf{H} \in \mathbf{R}^{n \times n}$  是一个秩为  $r$  的矩阵,  $r \leq n \leq N$ , 则  $\mathbf{H}$  的 COD 表示为

$$\mathbf{H} = \mathbf{UCV}^\top = \mathbf{U} \begin{bmatrix} \mathbf{C}_{11} & \mathbf{0} \\ \mathbf{0} & \mathbf{0}_{(N \times n)} \end{bmatrix} \mathbf{V}^\top \quad (9)$$

式中  $\mathbf{U} \in \mathbf{R}^{N \times N}$ ,  $\mathbf{V} \in \mathbf{R}^{n \times n}$  为正交矩阵,  $\mathbf{C}_{11} \in \mathbf{R}^{r \times r}$  为非奇异矩阵。

**推论** 设  $\mathbf{H} \in \mathbf{R}^{n \times n}$  是一个秩为  $r$  的矩阵,  $r \leq n \leq N$ , 其 COD 由式(9)给出; 将正交矩阵  $\mathbf{U}$  和  $\mathbf{V}$  分别按列分割为  $\mathbf{U} = [\mathbf{U}_1 \ \mathbf{U}_2]$  及  $\mathbf{V} = [\mathbf{V}_1 \ \mathbf{V}_2]$ , 其中  $\mathbf{U}_1, \mathbf{V}_1$  分别为  $\mathbf{U}, \mathbf{V}$  的前  $r$  列, 则  $\mathbf{H}$  的 COD 可简化表示为

$$\mathbf{H} = \mathbf{U}_1 \mathbf{C}_{11} \mathbf{V}_1^\top \quad (10)$$

**证明** 将  $\mathbf{U}$  和  $\mathbf{V}$  代入式(9), 可得  $\mathbf{H} = \mathbf{UCV}^\top$

$$= [\mathbf{U}_1 \ \mathbf{U}_2] \begin{bmatrix} \mathbf{C}_{11} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{V}_1^\top \\ \mathbf{V}_2^\top \end{bmatrix} = [\mathbf{U}_1 \mathbf{C}_{11} \ \mathbf{0}] \begin{bmatrix} \mathbf{V}_1^\top \\ \mathbf{V}_2^\top \end{bmatrix} = \mathbf{U}_1 \mathbf{C}_{11} \mathbf{V}_1^\top.$$

证毕

由于式(10)是 COD 的一种简洁表示形式, 我们称之为简化完全正交分解(Reduced Complete Orthogonal Decomposition, RCOD)。

根据  $\mathbf{H}$  的 RCOD 表示形式, 很容易验证:

$$\mathbf{H}^\dagger = (\mathbf{U}_1 \mathbf{C}_{11} \mathbf{V}_1^\top)^\dagger = \mathbf{V}_1 \mathbf{C}_{11}^{-1} \mathbf{U}_1^\top \quad (11)$$

则 ELM 的输出权值可重写为

$$\hat{\beta} = \mathbf{H}^\dagger \mathbf{T} = \mathbf{V}_1 \mathbf{C}_{11}^{-1} \mathbf{U}_1^\top \mathbf{T} \quad (12)$$

比较式(8)和式(9)可以发现, SVD 可视为一种特殊的 COD 方法, 因为其具有与 COD 类似的结构形式, 只不过在 SVD 的分解结构中, 其中间矩阵  $\Sigma$  是一种更特殊的对角化矩阵, 这也使得 SVD 方法的计算过程更为复杂。在许多计算环境下, 我们可以牺牲这种对角结构来省去不必要的冗余计算, 以得到更加高效的分解方法, 这也是 COD(RCOD)背后

的主要思想。显然, 基于 RCOD 的改进 ELM 算法较基于 SVD 的原始 ELM 算法具有更高的计算效率, 我们称之为快速极限学习机(Fast ELM, FELM)。

### 3 机场噪声一体化预测模型

机场噪声一体化预测模型是一种面向机场噪声数据的时间序列预测模型。本节首先简述了时间序列预测的基本思想及其相关的相空间重构理论; 然后分析了传统时间序列建模方法存在的弊端, 并提出了一种新的基于快速极限学习机和改进差分进化算法的机场噪声一体化预测模型。

#### 3.1 时间序列预测及相空间重构

时间序列指按时间次序排列且相互关联的随机变量序列。时间序列预测建立在相空间重构理论<sup>[13]</sup>和 Takens 嵌入定理<sup>[14]</sup>基础之上, 其基本思想是时序系统中任一分量的演化由与之相互作用的其它分量所决定, 这些相关分量的信息隐含在任一分量的发展过程中, 可以从观测到的时间序列数据中提取和恢复出原始系统的内部规律。

给定一组观测时间序列  $\{x(t) | t = 1, 2, \dots, N\}$ , Takens 嵌入定理应用延时坐标法重构系统相空间, 即选择一个合适的嵌入维数  $m$ , 时间延迟  $\tau$ , 由  $x(t)$  可重构出一组新的相空间矢量:

$$\mathbf{X}(t) = \{x(t), x(t-\tau), \dots, x(t-(m-1)\tau)\}, \\ t = (m-1)\tau + 1, (m-1)\tau + 2, \dots, N \quad (13)$$

Takens 进一步证明, 对于重构的相空间矢量序列, 存在一个平滑的映射  $F: \mathbf{R}^m \rightarrow \mathbf{R}^m$  使得

$$\mathbf{X}(t+h) = F(\mathbf{X}(t)) \quad (14)$$

由式(14)很容易推导出另一个等价映射  $f: \mathbf{R}^m \rightarrow \mathbf{R}$ , 即

$$x(t+h) = f(x(t), x(t-\tau), \dots, x(t-(m-1)\tau)) \quad (15)$$

其中  $f$  即为所求的预测模型,  $h > 0$  为前向预测步长。

#### 3.2 一体化预测模型

机场噪声数据是噪声监测系统以时间为次序按照固定频率依次采集的噪声强度值, 从时间的维度来看, 所采集的机场噪声数据集是一种典型的时间序列。因此, 从时间序列预测的角度出发, 通过对机场历史噪声时间序列数据进行分析建模, 以揭示出机场噪声时序系统的内在特性和发展变化规律, 并对未来一段时间内的机场噪声趋势进行有效预测, 能够为控制噪声影响, 优化机场周边环境提供决策支持和理论依据。

预测模型的构建是进行时间序列预测的前提和基础。时序系统的建模过程主要包括以下两个关键步骤: (1)根据嵌入理论计算最佳嵌入维数和时间延迟, 并对时间序列进行相空间重构, 得到重构后的

相空间点；(2)选择学习模型及模型参数，并对相空间点进行学习拟合以得到最终的预测模型。

在传统的时间序列建模过程中，相空间重构参数和模型参数的选择是分两个阶段独立完成的，这种方式割裂了二者之间的内在联系，限制了模型整体预测性能的提高；实验表明，即便各自阶段所选择的参数是局部最优的，但其串行组合未必是全局最优的。为了克服传统两阶段建模方法存在的不足，进一步提高模型的稳定性和整体预测性能，本文提出一种基于 FELM 和 DE 的机场噪声一体化预测模型，其核心思想是采用一体化参数选择策略来同步优化相空间重构参数(嵌入维数  $m$ ，时间延迟  $\tau$ )和模型参数(FELM 的隐层节点个数  $n$ )。在该模型中，FELM 作为一种高效的学习算法用来对时间序列进行建模；同时，基于交叉验证准则，我们采用改进的 DE 算法来同步搜索最优的参数组合  $(m, \tau, n)$ 。得益于 DE 强大的全局搜索能力和 FELM 高效而准确的学习能力，该一体化预测模型不仅能够保证所选择的参数组合是全局最优或近似最优的以增强模型的预测精度，同时也保证了参数寻优的高效性。

图 1 给出了该一体化预测模型的双层混合结构示意图。从 FELM 的层级来看，FELM 主要用来对不同参数组合条件下的时间序列进行学习建模并返回当前条件下的验证误差；从 DE 的层级来看，所有的参数向量都需要经历初始化、代价函数计算、变异和交叉、评价和选择这 4 个进化步骤，并通过多次迭代搜索以选择出最优的参数组合。每个步骤的实现细节描述如下：

步骤 1 初始化：对  $NP$  个由  $(m, \tau, n)$  组成的 3 维参数向量个体按式(16)进行初始化：

$$\theta_{i,G} = \theta_{\min} + \text{rand}(0,1) \cdot (\theta_{\max} - \theta_{\min}), i=1,2,\dots, NP \quad (16)$$

式中， $\theta_{\min} = (m_{\min}, \tau_{\min}, n_{\min})$  及  $\theta_{\max} = (m_{\max}, \tau_{\max}, n_{\max})$  分别表示预设的最小、最大参数边界， $G$  表示当前进化代数，在初始化阶段， $G = 1$ 。

步骤 2 计算代价函数：本文采用广泛使用的

交叉验证法进行参数选择。对于每个目标参数向量  $\theta_{i,G}$ ，首先在训练集上调用 FELM 算法(式(17))得到当前参数条件下的网络输出权值，然后在验证集上计算对应的验证误差(本文采用平均绝对误差 MAE)作为  $\theta_{i,G}$  的代价函数(式(18))：

$$\beta = H^T T = V_1 C_{11}^{-1} U_1^T T \quad (17)$$

$$f(\theta_{i,G}) = \text{MAE}_{i,G} = \frac{1}{N} \sum_{j=1}^N |H\beta - T| \quad (18)$$

步骤 3 变异和交叉：变异和交叉操作遵循 DE 算法的一般准则，用来生成潜在的下一代个体。其中，变异操作采用式(19)生成新的变异向量：

$$v_{i,G+1} = \theta_{r_1,G} + F \cdot (\theta_{r_2,G} - \theta_{r_3,G}) \quad (19)$$

式中  $r_1, r_2, r_3 \in \{1, 2, \dots, NP\}$  为随机生成且相互各异的序号值， $F$  为缩放因子；交叉操作采用式(20)，式(21)以进一步增强扰动参数向量的多样性。

$$u_{i,G+1} = (u_{1i,G+1}, u_{2i,G+1}, u_{3i,G+1}) \quad (20)$$

$$u_{ji,G+1} = \begin{cases} v_{ji,G+1}, & \text{rand } b(j) \leq \text{CR 或 } j = \text{rnbr}(i) \\ \theta_{ji,G}, & \text{rand } b(j) > \text{CR 或 } j \neq \text{rnbr}(i) \end{cases}, j = 1, 2, 3 \quad (21)$$

式(21)中， $\text{rand } b(j)$  为输出在  $[0, 1]$  之间的随机数发生器的第  $j$  个估计值，CR 为范围在  $[0, 1]$  之间的交叉概率， $\text{rnbr}(i)$  为  $\{1, 2, 3\}$  中随机选择的一个整数，以确保  $u_{i,G+1}$  至少从  $v_{i,G+1}$  中获得一个参数。

步骤 4 评价与选择：原始 DE 算法使用贪婪准则对试验向量  $u_{i,G+1}$  和目标向量  $\theta_{i,G}$  进行比较，具有较小代价函数值的向量将被选中进入下一代。然而，对于 ELM(FELM)而言，仅仅使用代价函数(验证误差)作为评价标准是不合适的。根据文献[10]的研究结论，ELM 算法具有较为稳定的泛化能力，亦即 ELM 能在一个较大的隐层节点范围内均取得同样小的验证误差，而更多的隐层节点意味着更多的训练时间和测试时间；更为严重的是，过多的隐层节点还可能导致模型的过拟合风险。因此，为了得到一个准确而紧凑的模型结构，我们将隐层节点个数同验证误差结合起来作为参数向量评估与选择的标准：当  $u_{i,G+1}$  与  $\theta_{i,G}$  的代价函数相差不大时，具有较少隐层节点个数的参数向量将被优先选择作为新的个体进入下一个进化代。完整的选择策略如式(22)所示。

$$\theta_{i,G+1} = \begin{cases} u_{i,G+1}, & f(\theta_{i,G}) - f(u_{i,G+1}) > \varepsilon f(\theta_{i,G}) \\ u_{i,G+1}, & |f(\theta_{i,G}) - f(u_{i,G+1})| < \varepsilon f(\theta_{i,G}), \\ & u_{3i,G+1} < \theta_{3i,G} \\ \theta_{i,G}, & \text{其它} \end{cases} \quad (22)$$

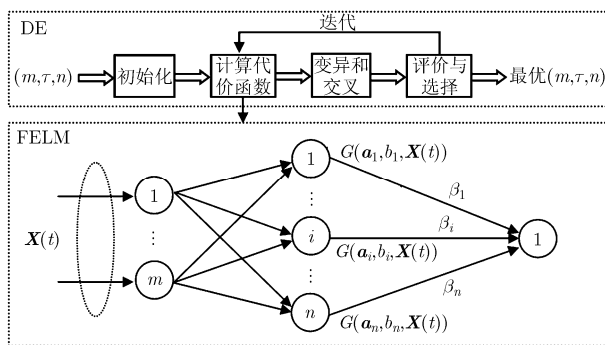


图 1 一体化预测模型的结构

式中  $\varepsilon$  为预设的误差容忍度。步骤 3 和步骤 4 循环进行直到达到最大迭代代数，并选择最后一代中的最佳个体作为最终的最优参数组合。

## 4 实验

### 4.1 机场噪声监测数据集

机场噪声数据的采集是进行机场噪声分析、预测及影响评估的基础。为了全面准确地获取到实际的机场噪声数据，我们在北京首都国际机场周边设置了 22 个噪声监测站点，这些站点按照一定的原则分布在机场周围半径约为 10 km 的圆型区域内，且每个站点分别位于不同的环境，如居民区、学校、工厂等。在每个噪声监测点，噪声监测系统以秒为采样频率对机场噪声数据进行实时采集，即实测数据为每秒采集一次的噪声强度值，噪声评价量为等效连续声级  $L_{eq}$ ，单位为 dB。

通过观察分析已有历史监测数据的完整性和可用性，我们分别选取 2 号和 12 号监测点 2010 年 2 月 2 日至 2010 年 8 月 20 日共 200 d 的噪声数据，构建了两组实验数据集。由于机场噪声具有声级高、间断性等特点，取每天的算术平均值进行分析预测。对于两组噪声数据序列，选取最后 10 d 的数据作为测试集，中间 50 d 的数据作为验证集，其余 140 d 的数据作为训练集。

### 4.2 实验设计

本文预测模型所使用的实验参数如表 1 所示，其中，迭代代数、个体总数、缩放因子、交叉概率的设置参考 DE 算法的一般准则<sup>[9]</sup>；嵌入维度和时间延迟的预设范围根据一般经验进行设置；此外，根据文献[10]，ELM 中隐层节点的上限为训练集的大小，而本文中经相空间重构以后的训练集的大小会略小于原始训练集的大小(140)，故我们将隐层节点的范围宽泛地设置为[1, 140]。

为了评估模型的预测性能并便于同其他文献的实验结果进行比较，我们选择平均绝对误差(MAE)

作为预测误差度量标准，计算公式为

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (23)$$

其中  $y_i$ ,  $\hat{y}_i$  分别为实测值和预测值,  $N$  为实验数据的总个数。

### 4.3 实验结果与分析

根据已有的两组噪声数据集，我们首先以 2 号监测点为例对机场噪声数据的变化趋势进行初步分析，图 2 给出了 2 号监测点 200 d 的日均噪声变化曲线图。如图 2 所示，从整体上看，所有噪声数据均在[40,55]区间内波动，且表现出时间序列数据常有的混沌特性，即外在的无序变化趋势。下面的实验将从时间序列预测的角度出发对机场噪声数据进行重构分析，挖掘出机场噪声的内部演化规律并实现对机场噪声的有效预测。

为了验证本文提出的 FELM 算法较原始 ELM 算法在执行效率上的优越性，两种不同的一体化预测模型(DE-ELM 及 DE-FELM)在相同实验条件下进行对照实验。首先，使用交叉验证法，结合一体化参数选择策略，我们在训练集和验证集上运行模型以获得最优的参数组合  $(m, \tau, n)$ ，实验结果如表 2 所示。由表 2 可得，对于两个监测点的噪声数据集，DE-FELM 与 DE-ELM 在验证误差上基本相当，但前者的参数寻优时间明显小于后者，由此可见 FELM 在保持 ELM 算法原有泛化能力的同时在计算效率上确实有较为显著的提升，且模型的参数选择过程可在数秒内自动搜索完成，建模效率很高。

根据一体化参数选择的结果，我们采用得到的最优  $(m, \tau, n)$  作为预测模型的最终参数，分别对 2 个监测点上的机场噪声时间序列数据在测试集上进行预测。图 3 和图 4 分别给出了 DE-FELM 在 2 号和 12 号监测点的预测结果。由图可以看出，预测噪声折线图能较好地跟踪实测噪声的变化趋势，且对于大部分样本点，预测值与实际值的拟合程度较好，可见本文提出的一体化预测模型对于机场噪声预测是积极有效的。

为了进一步验证本文所提模型在预测精度上的优越性，我们将本文的预测结果与其他常用时间序

表 1 模型参数设置

参数	数值(区间)
迭代代数( $G$ )	50
个体总数( $NP$ )	20
缩放因子( $F$ )	0.6
交叉概率( $CR$ )	0.4
误差容忍度( $\varepsilon$ )	0.02
嵌入维度( $m$ )	[1, 30]
时间延迟( $\tau$ )	[1, 3]
隐层节点个数( $n$ )	[1, 140]

表 2 一体化参数选择的结果

噪声数据	模型	最优 $(m, \tau, n)$	验证 MAE	寻优时间(s)
2 号点	DE-ELM	(2,2,11)	0.6766	3.7031
	DE-FELM	(2,2,10)	0.6681	1.8750
12 号点	DE-ELM	(1,1,9)	0.7567	3.0313
	DE-FELM	(1,2,7)	0.7690	2.2031




图2 机场噪声变化趋势图




图3 2号监测点的预测结果




图4 12号监测点的预测结果

列预测模型的预测结果进行了比较,包括灰色模型(GM)<sup>[15]</sup>,最小二乘支持向量机(LSSVM)<sup>[16]</sup>,奇异谱分析(SSA)<sup>[17]</sup>等,实验结果比较如表3所示。容易看出,本文提出的一体化预测模型具有最小的预测MAE,较其他模型具有一定的优越性。需要补充说明的是,如引言中所述,传统的机场噪声预测模型如INM, NOISEMAP等需要众多繁杂的实际参数作为模型输入,限于目前实验条件下部分实际参数的缺失,相关实验性能比较未能给出,这也从另一方面说明了本文模型更具简洁性和实用性。

表3 各模型的预测MAE比较

模型	2号点	12号点
GM	1.22	1.45
LSSVM	1.27	1.23
SSA	1.12	1.64
文献[18]模型	1.09	1.63
本文 DE-ELM	0.98	1.17
本文 DE-FELM	0.99	1.16

## 5 结论

机场噪声预测对于控制机场噪声影响,优化机场周边环境具有非常重要的现实意义。本文从时间序列预测的角度出发,引入相空间重构理论,提出一种基于FELM和DE算法的机场噪声一体化预测模型。与传统机场噪声预测模型对输入参数完整性和准确性的苛刻要求相比,本文提出的一体化预测模型完全基于历史监测数据而构建,建模成本大大降低;而且在建模过程中,所有参数选择均采用DE这一启发式搜索算法自动同步完成,无需人工干预,建模效率较高;此外,借助FELM准确而高效的学习拟合能力,该模型能较好地挖掘出机场噪声数据的内部演化规律并实现对机场噪声未来变化趋势的有效预测。目前,该预测模型已成功应用于北京首都国际机场噪声监测数据集,显示出良好的实用性和预测效果。

## 参考文献

- [1] SARI D, OZKURT N, AKDAG A, *et al.* Measuring the levels of noise at the İstanbul Atatürk Airport and comparisons with model simulations[J]. *Science of The Total Environment*, 2014, 482(6): 472-479. doi: 10.1016/j.scitotenv.2013.07.091.
- [2] OZKURT N, HAMAMCI S F, and SARI D. Estimation of airport noise impacts on public health. A case study of İzmir Adnan Menderes Airport[J]. *Transportation Research Part D: Transport and Environment*, 2015, 36(5): 152-159. doi: 10.1016/j.trd.2015.02.002.
- [3] 陈海燕, 杨冰欣, 徐涛, 等. 基于模糊支持向量回归的机场噪声预测[J]. 南京航空航天大学学报, 2013, 45(5): 722-726. CHEN Haiyan, YANG Bingxin, XU Tao, *et al.* Airport noise prediction based on fuzzy support vector regression[J]. *Journal of Nanjing University of Aeronautics & Astronautics*, 2013, 45(5): 722-726.
- [4] FILIPPONE A and BERTSCH L. Comparison of aircraft noise models with flyover data[J]. *Journal of Aircraft*, 2014, 51(3): 1043-1047. doi: 10.2514/1.C032368.
- [5] GUARNACCIA C, QUARTIERI J, TEPEDINO C, *et al.* An analysis of airport noise data using a non-homogeneous Poisson model with a change-point[J]. *Applied Acoustics*, 2015, 91(4): 33-39. doi: 10.1016/j.apacoust.2014.12.002.
- [6] FILIPPONE A. Aircraft noise prediction[J]. *Progress in Aerospace Sciences*, 2014, 68(7): 27-63. doi: 10.1016/j.paerosci.2014.02.001.
- [7] 徐涛, 燕宪金, 杨国庆. 基于神经网络集成的单个飞行事件噪声预测模型[J]. 中国环境科学, 2014, 34(2): 539-544. XU Tao, YAN Xianjin, and YANG Guoqing. Prediction model of noise event for single flight based on neural network ensemble[J]. *China Environmental Science*, 2014, 34(2): 539-544.
- [8] 徐涛, 杨奇川, 吕宗磊. 一种基于动态集成学习的机场噪声预测模型[J]. 电子与信息学报, 2014, 36(7): 1631-1636. doi: 10.3724/SP.J.1146.2013.01410. XU Tao, YANG Qichuan, and LU Zonglei. A prediction model of airport noise based on the dynamic ensemble learning[J]. *Journal of Electronics & Information Technology*, 2014, 36(7):

- 1631–1636. doi: 10.3724/SP.J.1146.2013.01410.
- [9] STORN R and PRICE K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces[J]. *Journal of Global Optimization*, 1997, 11(4): 341–359. doi: 10.1023/A:1008202821328.
- [10] HUANG G B, ZHU Q Y, and Siew C K. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70(1): 489–501. doi:10.1016/j.neucom.2005.12.126.
- [11] HOUGH P D and VAVASIS S A. Complete orthogonal decomposition for weighted least squares[J]. *SIAM Journal on Matrix Analysis and Applications*, 1997, 18(2): 369–392. doi:10.1137/S089547989528079X.
- [12] GOLUB G H and VAN LOAN C F. *Matrix Computations*[M]. Baltimore: JHU Press, 2012: 274–283.
- [13] PACKARD N H, CRUTCHFIELD J P, FARMER J D, *et al.* Geometry from a time series[J]. *Physical Review Letters*, 1980, 45(9): 712–716. doi:10.1103/PhysRevLett.45.712.
- [14] TAKENS F. Detecting strange attractors in turbulence[J]. *Dynamical Systems and Turbulence*, 1981, 898(1): 366–381.
- [15] KAYACAN E, ULUTAS B, and KAYNAK O. Grey system theory-based models in time series prediction[J]. *Expert Systems with Applications*, 2010, 37(2): 1784–1789. doi: 10.1016/j.eswa.2009.07.064.
- [16] ZHANG N, WILLIAMS C, and BEHERA P. Water quantity prediction using least squares support vector machines (LS-SVM) Method[J]. *Journal of Systemics, Cybernetics and Informatics*, 2014, 2(4): 53–58.
- [17] AFSHAR K and BIGDELI N. Data analysis and short term load forecasting in Iran electricity market using singular spectral analysis (SSA)[J]. *Energy*, 2011, 36(5): 2620–2627. doi: 10.1016/j.energy.2011.02.003.
- [18] 温冬琴, 王建东. 基于奇异谱分析的机场噪声时间序列预测模型[J]. *计算机科学*, 2014, 41(1): 267–270.
- WEN Dongqin and WANG Jiandong. Prediction model for airport-noise time series based on SSA[J]. *Computer Science*, 2014, 41(1): 267–270.
- 徐 涛: 男, 1962 年生, 教授, 博士生导师, 研究方向为数据挖掘、智能信息处理、图形图像与可视化技术等.
- 郭 威: 男, 1983 年生, 讲师, 博士生, 研究方向为数据挖掘、机器学习、时间序列预测等.
- 吕宗磊: 男, 1981 年生, 副教授, 博士, 研究方向为数据挖掘、机器学习与知识工程等.