

文章编号:1007-5321(2021)04-0089-06

DOI:10.13190/j.jbupt.2020-188

# 基于动态模式分解的移动用户信道容量预测算法

朱 军<sup>1</sup>, 唐宝煜<sup>1</sup>, 李 凯<sup>2</sup>

(1. 安徽大学 电子信息工程学院, 合肥 230601; 2. 上海科技大学 创意与艺术学院, 上海 201210)

**摘要:** 在多输入多输出环境下,为了能够连续预测出移动用户的信道容量并以此合理地分配用户资源,提出了一种基于动态模式分解(DMD)的信道容量预测方法及其优化方法:基于经验模态分解的选择性归一化动态模式分解(ESN-DMD)。仿真结果表明,DMD 算法只适用于预测低移速低复杂度的用户信号,ESN-DMD 算法可以预测不同移速的用户信道容量。

**关键词:** 多输入多输出; 动态模式分解; 经验模态分解; 选择性归一化; 信道容量预测

中图分类号: TN929.5

文献标志码: A

## Prediction Algorithm of Mobile User Channel Capacity Based on Dynamic Mode Decomposition

ZHU Jun<sup>1</sup>, TANG Bao-yu<sup>1</sup>, LI Kai<sup>2</sup>

(1. School of Electronics and Information Engineering, Anhui University, Hefei 230601, China;

2. School of Creativity and Art, Shanghai Tech University, Shanghai 201210, China)

**Abstract:** To predict the channel capacity of mobile users and appropriately allocate user resources in multiple-input-multiple-output systems, a channel capacity prediction method based on dynamic mode decomposition (DMD) is proposed. Meanwhile, a selective normalized dynamic mode decomposition method based on empirical mode decomposition (ESN-DMD) is proposed to optimize the system. The simulation results show that the DMD algorithm is only suitable for the prediction of user signals at low moving speed and low complex, while the ESN-DMD algorithm can adapt to the prediction of channel capacity of users with different moving speeds.

**Key words:** multiple input multiple output; dynamic mode decomposition; empirical mode decomposition; selective normalization; channel capacity prediction

多输入多输出(MIMO, multiple input multiple output)技术是第5代移动通信系统(5G, the fifth generation of mobile communications system)的关键技术之一,具有频谱效率高、数据传输速率快的优点<sup>[1]</sup>。在MIMO蜂窝网移动通信中,准确预测不同移动用户的信道容量能够合理进行资源调度,因此,有效的信道预测方法可以大力推进MIMO在实际场

景中的应用<sup>[2]</sup>。在信道预测领域,传统算法有自回归(AR, autoregressive)预测模型<sup>[3]</sup>和基于离散多径信道参数的预测模型<sup>[4]</sup>。然而,AR模型是基于信道状态值的线性组合进行预测的,并不适用于非线性非平稳的MIMO信道状态。而基于离散多径信道参数预测模型的前提假设是信道的传播路径静止,即信道路径数固定,显然不符合MIMO环境的路径数

收稿日期: 2020-09-28

基金项目: 安徽省科技重大专项项目(18030901010)

作者简介: 朱 军(1968—),女,副教授,硕士生导师, E-mail:junzhu@ahu.edu.cn.

受用户位置的改变而改变. 动态模式分解 (DMD, dynamic mode decomposition) 已成为从实验数据集分析非线性系统动力学的有力工具<sup>[5]</sup>. 近年来, DMD 算法已应用到许多复杂动力系统的环境中, 如情感计算<sup>[6]</sup>、传染病传播分析<sup>[7]</sup>、神经系统科学<sup>[8]</sup>等. Nayak 等<sup>[9]</sup>将 DMD 算法用于振荡等离子体的行为预测上, 从而成功预测未来电场的分布. Kutichira 等<sup>[10]</sup>试图使用 DMD 算法进行股价预测, 但在预测时, 如果只关注小部分股票, 则预测结果并不令人满意, 还必须同时考虑不同行业 and 不同公司之间的依赖性.

笔者将 DMD 算法应用到预测移动用户的信道信息上, 并验证了 DMD 算法在预测低移速低复杂度信道信息上的性能优越性. 对于高移速高复杂度的信道信息, DMD 算法预测的误差过大, 故提出使用选择性归一化动态模式分解 (SN-DMD, selective normalized dynamic mode decomposition) 算法来预测高移速高复杂度的信道信息, 最终使用基于经验模式分解的选择性归一化动态模式分解 (ESN-DMD, selective normalized dynamic mode decomposition based on empirical mode decomposition) 算法来分辨 DMD 算法和 SN-DMD 算法的使用环境, 从而达到预测不同移速下用户信道容量的目的.

## 1 用户数据模型

使用的用户信道数据来自于上海科技大学的上海雾计算实验室 5G 仿真平台. 用户信道模型采用标准 3GPP 38.901 规定的城市宏蜂窝 (3D-UMa, three dimensional urban macro cell) 模型, 该模型包含了大尺度衰落模型、小尺度衰落模型以及天线相关性模型. 每个基站有 3 个扇区, 每个扇区有 10 个用户, 用户在扇区中随机分布, 每个用户天线数为 2. 扇区配置 64 根天线, 基站天线采用面阵配置, 每行天线数为 16, 一共 4 行, 共计 64 根天线, 在每个资源区块 (RB, resource block) 中只选择 1 个子载波, 子载波间隔为 15 kHz, 带宽 20 MHz, 共 100 个 RB. 传输时间间隔 (TTI, transmission time interval) 设为 1 ms. 考虑到在实际中, 每个用户移动时都有自己的目的地, 如行人基本都是在人行道上沿直线行走, 而不会像分子运动一样无规则移动, 所以设置用户按照固定直线路线移动, 在短时间内用户的移动速度和基本环境不发生变化. 所有用户数据为复数形式, 用户数据模型拓扑图如图 1 所示.




图1 用户数据模型拓扑结构

## 2 DMD 算法预测移动用户信道容量

DMD 算法将一个动态系统转换成由特征值控制的模态叠加, 它的基本假设是: 给定一个动态系统的快照序列, 用矩阵表示为<sup>[11]</sup>

$$\mathbf{X}_1^N = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\} \quad (1)$$

其中:  $\mathbf{x}_i$  为系统第  $i$  个时刻的状态,  $\mathbf{X}_1^N$  为从第 1 个时刻到第  $N$  个时刻的序列集合. 在传输场景中, 由于每个用户天线数为 2, 基站端天线数为 64, 将一个用户  $2 \times 64$  的信道矩阵转化为  $1 \times 128$  向量形式, 即每个  $\mathbf{x}_i$  的维度是 128, 而  $\mathbf{x}_{i+1}$  即为  $\mathbf{x}_i$  下一时刻的状态.

假设有一个不可访问的黑盒线性算子  $\mathbf{A}$  可将状态  $\mathbf{x}_i$  连接到  $\mathbf{x}_{i+1}$ , 即

$$\mathbf{x}_{i+1} = \mathbf{A}\mathbf{x}_i \quad (2)$$

其中  $i = 1, 2, \dots, N-1$ . 该线性算子在整个序列区间内是近似相同的. 如果该系统是非线性的, 那么此假设相当于线性切线近似. 因此可将式 (1) 的快照序列表示为 Krylov 序列:

$$\mathbf{X}_1^N = \{\mathbf{x}_1, \mathbf{A}\mathbf{x}_1, \mathbf{A}^2\mathbf{x}_1, \dots, \mathbf{A}^{N-1}\mathbf{x}_1\} \quad (3)$$

将其分为 2 部分, 即

$$\mathbf{A}\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{N-1}\} = \{\mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_N\} \quad (4)$$

或矩阵形式:

$$\mathbf{A}\mathbf{X}_1^{N-1} = \mathbf{X}_2^N \quad (5)$$

为了避免矩阵的数值病态, Schmid 提出了一种基于快照矩阵的奇异值分解 (SVD, singular value decomposition) 方法, 并截断最小奇异值来抑制不良条件, 有

$$\mathbf{X}_1^{N-1} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^* \quad (6)$$

其中:  $\mathbf{\Sigma} = \text{diag}(\sigma_i)_{i=1}^{\min(m,n)}$ ,  $\sigma_1 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$ ,  $\sigma_i$

为  $X_1^{N-1}$  的第  $i$  个奇异值. 定义  $U_k = U(:, 1:k)$ ,  $\Sigma_k = \Sigma(1:k, 1:k)$ ,  $V_k = V(:, 1:k)$ , 所以有  $X_1^{N-1} \approx U_k \Sigma_k V_k^*$ , 而  $X_2^N$  为

$$X_2^N = A X_1^{N-1} = A U_k \Sigma_k V_k^* \quad (7)$$

计算  $A$  相对于  $U_k$  的投影  $\tilde{A}$ :

$$\tilde{A} \equiv U_k^* (A U_k) = U_k^* (X_2^N V_k \Sigma_k^{-1}) \quad (8)$$

通过分解特征值获得  $\tilde{A}$  的特征值  $\Lambda_k$  及对应特征向量  $W_k$ :

$$\tilde{A} W_k = W_k \Lambda_k \quad (9)$$

其中  $\Lambda = \text{diag}(\lambda_i)_{i=1}^k$ .  $A$  的特征值等价于  $\tilde{A}$  的特征值, 而 DMD 算法的模式由  $\Phi$  给出:

$$\Phi = U_k W_k \quad (10)$$

可通过  $X_1^N$  获得的 DMD 算法模式及对应的特征值来预测该系统第  $(N+1)$  个状态, 有

$$x_{N+1} = \Phi \Lambda^N \Phi^+ x_1 \quad (11)$$

其中  $\Phi^+$  为  $\Phi$  的伪逆.

将预测的信道矩阵转换为信道容量, 可以表示为<sup>[12]</sup>

$$C = \text{lb} \{ \det [I_n + \gamma (H H^*)] \} \quad (12)$$

其中:  $I_n$  为单位矩阵,  $\gamma$  为信干噪比,  $H$  为用户的信道矩阵,  $H^*$  为  $H$  的共轭转置.

### 3 ESN-DMD 算法预测移动用户信道容量

#### 3.1 SN-DMD 算法

DMD 算法在面对低移速低复杂度的信号时, 可以轻松抓住系统的模式, 而对于剧烈变化的信号则无能为力. 预测高移速高复杂度信号时产生巨大误差的主要原因是在计算系统模式所对应的特征值时, 该特征值只能表示为剧烈变化下的一个时间步上的数值特征, 若一味地将该时间段内的剧烈变化特征用来预测下一时间段的系统信息, 无疑会产生不可接受的误差结果.

为了对高移速高复杂度信号的系统预测特征进行控制, 对所计算的系统模式特征值进行选择归一化, 即将其中绝对值大于 1 的特征值进行归一化, 有

$$\bar{\Lambda}_k = \text{diag}(\bar{\lambda}_i)_{i=1}^k \quad (13)$$

其中

$$\bar{\lambda}_i = \begin{cases} \lambda_i, & |\lambda_i| \leq 1 \\ \frac{\lambda_i}{|\lambda_i|}, & |\lambda_i| > 1 \end{cases} \quad (14)$$

通过  $X_1^N$  获得的 DMD 算法模式及其对应的选择性归一化特征值, 来预测该系统第  $(N+1)$  个状态:

$$x_{N+1} = \Phi \bar{\Lambda}_k^N \Phi^+ x_1 \quad (15)$$

首先, 取图 1 所示用户数据模型所有用户的 500 个 TTI 信道复数数据, 然后对 1~5 个 TTI 数据进行 DMD 算法预测, 获取该时间段的模式及对应特征值, 并以此进行 6~10 个 TTI 数据的预测; 再用 6~10 个 TTI 原始数据来预测 11~15 个 TTI 数据, 依此类推.

如图 2 所示, 对于用户速度较低的低复杂度信号而言, DMD 算法在预测 MIMO 系统矩阵信息方面的优势明显, 但是对用户移速较高的高复杂度信号, DMD 算法无法再准确地抓住系统的变化模式, 误差已经达到无法接受的地步, 此时 DMD 算法已无法再用于高移速用户信道的容量预测. 在用户移速较高时, 相较于 DMD 算法来说, SN-DMD 算法具有较好的预测能力, 能够保持信道系统的模式且不会出现预测发散的情况. 然而, 当用户移速较低时, 如图 3(a) 所示, 虽然 SN-DMD 算法能够很好地预测出

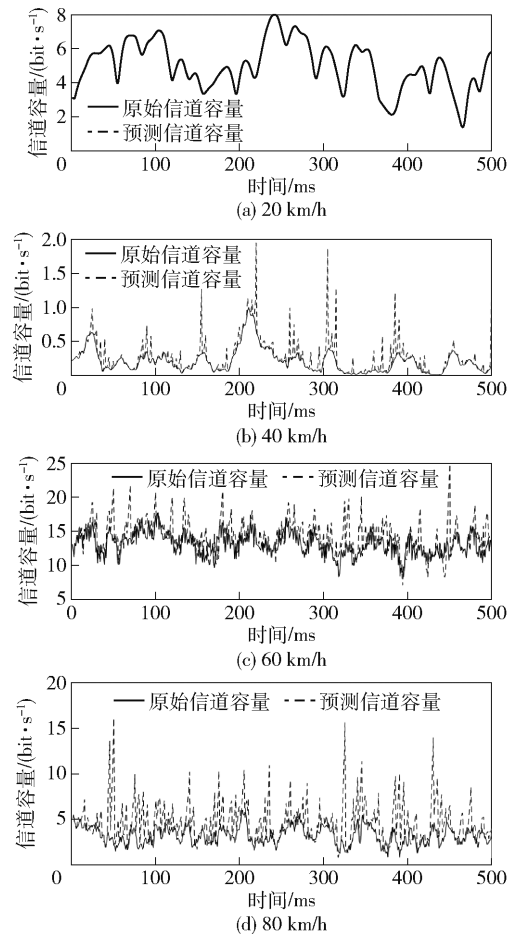


图2 用 DMD 算法预测不同移动速度下用户的信道容量

用户的信道容量,但在局部区域会出现动荡,并没有DMD预测来的平滑和准确.




图3 用SN-DMD算法预测不同移动速度下用户的信道容量

因此,在低移速时,DMD算法预测更加准确,在高移速时,SN-DMD算法预测误差更低.值得一提的是,SN-DMD算法之所以在低移速时的预测效果不如DMD算法,是因为其对导致预测发散的系统模态特征值进行了修正,所以,在高移速时,才能有效维持系统模态的主要特征并遏制预测发散.

图4所示为预测的相对误差随用户移动速度变化的曲线,可以看出,在用户移速较低时,DMD算法预测的平均相对误差更低,但用户移速较高时,SN-DMD算法平均相对误差更低.值得注意的是,用户移速为40 km/h时,使用SN-DMD算法预测信道容量的平均相对误差更低;而移速为50 km/h时,使用DMD算法预测信道容量的平均相对误差更低,这与上述结论并不一致.因此,在预测移动用户的信道容量时,移速并不是判断何时使用DMD和SN-DMD算法的最佳阈值.




图4 用DMD和SN-DMD算法预测的平均相对误差

### 3.2 基于经验模态分解的阈值区分

经验模态分解(EMD, empirical mode decomposition)是一种分析非平稳和非线性信号的算法,可将信号分解为若干单一频率的零均值信号,即固有模态函数(IMF, intrinsic mode function).此外,每一组IMF应满足以下原则<sup>[13-14]</sup>:

1) 极值的个数和零交叉的个数相等,或者它们的差不大于1;

2) 包络线的平均值在任何点上都为0.

设原始信号为 $x(t)$ ,EMD算法步骤如下:

**步骤1** 确定 $x(t)$ 的局部最大值和最小值;

**步骤2** 用三次样条插值分别构造 $x(t)$ 的下包络和上包络;

**步骤3** 计算下包络和上包络的均值;

**步骤4** 用原始数据减去均值,得到IMF分量的临时估计;

**步骤5** 检验临时估计是否满足IMF原则,若不满足,重复前面的步骤,直到满足原则为止;

**步骤6** 用原始信号 $x(t)$ 减去第1个IMF分量,得到残余信号;

**步骤7** 将残余信号作为新信号,重复步骤1~步骤7,直至不能提取更多的IMF.

EMD算法将 $x(t)$ 表示为一系列IMFs和残余之和,有

$$x(t) = \sum_{i=1}^k f_i + d(t), \quad 1 \leq i \leq k \quad (16)$$

其中: $f_i$ 为IMF分量, $k$ 为IMFs的个数.

EMD算法可将输入信号分解为有限的基本分量,每个分量具有不同的时间尺度,且第1个分量具有最小的时间尺度.随着分解的进行,时间尺度逐渐增加.因此,将原始信号分解成不同尺度的信号,就可以简化为特征信号<sup>[15]</sup>.对某一非平稳和非线



性信号进行 EMD 算法运算,得到 IMF<sub>s</sub> 的个数,即可判断该信号的复杂程度. 因此,信号越复杂,分解出的 IMF<sub>s</sub> 个数越多.

为了找出 DMD 和 SN-DMD 算法使用场景的阈值,对不同移速所有用户的信道容量进行 EMD 分解,对分解出的 IMF<sub>s</sub> 个数取平均值. 不同移速下所有用户的 IMF<sub>s</sub> 平均个数如表 1 所示.

表 1 移动用户信道容量信号的 IMF<sub>s</sub> 平均个数

移速/(km·h <sup>-1</sup> )	IMF <sub>s</sub> 平均个数
5	3.1
10	3.6
20	4.2
40	5.4
50	5.1
60	5.6
70	6.2
80	6.2
90	6.1
100	6.0
110	6.1
120	6.2

由表 1 和图 5 可知,对于 IMF<sub>s</sub> 个数平均值低于 5.4 的用户,其信道矩阵的变化更加平缓,适合使用 DMD 算法进行预测;而对于 IMF<sub>s</sub> 个数高于 5.4 的用户,其信道矩阵变化较为剧烈,需要使用 SN-DMD 算法进行预测. 因此 ESN-DMD 算法可以表述为:根据移动用户 IMF<sub>s</sub> 的平均个数自适应地使用 DMD 算法和 SN-DMD 算法,即 IMF<sub>s</sub> 平均个数小于 5.4 时使用 DMD 算法,IMF<sub>s</sub> 平均个数大于或等于 5.4 时使用 SN-DMD 算法.




图 5 不同 IMF<sub>s</sub> 平均个数对预测移动用户信道容量的影响

从图 6 和图 7 可以看出,ESN-DMD 算法既具有 DMD 算法在预测低复杂度信号时平滑和准确的优点,又具有 SN-DMD 算法在预测高复杂度信号时控制预测发散和平均相对误差低的优势. 基于 EMD 算法分解的 IMF<sub>s</sub> 平均个数可以自适应地将 DMD 算

法和 SN-DMD 算法的使用场景分辨出来,总是选择平均相对误差较小的预测方法进行预测.




图 6 用 ESN-DMD 预测不同移动速度下用户的信道容量




图 7 预测移动用户信道容量的平均相对误差

图 8 所示为传统的 AR 模型、多项式拟合模型<sup>[4]</sup>和 ESN-DMD 算法进行预测的误差比较. 由于在预测时,使用前 5 个 TTI 数据连续预测后 5 个 TTI 数据,所以 AR 预测使用 5 阶 AR 进行预测,多项式采用 4 次多项式进行拟合预测. 其中 AR(100)代表使用前 100 个 TTI 数据计算 AR 系数,而 AR(5)表示仅使用前 5

个数据计算 AR 系数. 从图 8 可见, AR(100)整体的预测误差比 ESN-DMD 算法稍高,而 AR(5)预测误差过大,无法用于实际预测. 多项式拟合在用户移速较低时,其预测误差很小,非常接近于 ESN-DMD 算法,但是达到 40 km/h 时,其预测误差出现陡升,这也印证了文献[4]中所描述的结果,即该方法具有局部特性,只适用于变化缓慢的短范围信道预测.




图8 不同预测方法的误差比较

## 4 结束语

提出使用 DMD 算法来连续预测移动用户信道容量,并且提出了以用户信道容量 IMF 平均个数作为判定条件的 ESN-DMD 算法. ESN-DMD 算法可以找出 DMD 和 SN-DMD 算法的使用场景,既保证了低移速低复杂度信号预测的平滑和准确,又解决了高移速高复杂度的预测发散问题. 实验结果表明, ESN-DMD 算法可以自适应地选择 DMD 算法或 SN-DMD 算法,可实时预测移动用户的信道容量,并应用于合理分配用户资源的 5G 优化技术中.

### 参考文献:

- [1] 梁晓林, 赵雄文, 李树, 等. 移动端到移动端 3D MIMO 宽带信道建模与仿真[J]. 北京邮电大学学报, 2017, 40(4): 91-97.  
Liang Xiaolin, Zhao Xiongwen, Li Shu, et al. Modeling and simulation for 3D wideband MIMO mobile-to-mobile radio channels[J]. Journal of Beijing University of Posts and Telecommunications, 2017, 40(4): 91-97.
- [2] Xie Hongxiang, Gao Feifei, Jin Shi. An overview of low-rank channel estimation for massive MIMO systems[J]. IEEE Access, 2016, 4: 7313-7321.
- [3] Baddour K E, Beaulieu N C. Autoregressive modeling for fading channel simulation[J]. IEEE Transactions on Wireless Communications, 2005, 4(4): 1650-1662.
- [4] Fan Lixing, Wang Qi, Huang Yongming, et al. Perform-

- ance analysis of low-complexity channel prediction for uplink massive MIMO[J]. IET Communications, 2016, 10(14): 1744-1751.
- [5] Héas P, Herzet C. Optimal low-rank dynamic mode decomposition[C]//2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). New Orleans: IEEE Press, 2017: 4456-4460.
- [6] le Ngo A C, See J, Phan R C W. Sparsity in dynamics of spontaneous subtle emotions: analysis and application[J]. IEEE Transactions on Affective Computing, 2017, 8(3): 396-411.
- [7] Proctor J L, Eckhoff P A. Discovering dynamic patterns from infectious disease data using dynamic mode decomposition[J]. International Health, 2015, 7(2): 139-145.
- [8] Brunton B W, Johnson L A, Ojemann J G, et al. Extracting spatial-temporal coherent patterns in large-scale neural recordings using dynamic mode decomposition[J]. Journal of Neuroscience Methods, 2016, 258: 1-15.
- [9] Nayak I, Teixeira F L. Dynamic mode decomposition for prediction of kinetic plasma behavior[C]//2020 International Applied Computational Electromagnetics Society Symposium(ACES). Monterey: IEEE Press, 2020: 1-2.
- [10] Kuttichira D P, Gopalakrishnan E A, Menon V K, et al. Stock price prediction using dynamic mode decomposition[C]//2017 International Conference on Advances in Computing, Communications and Informatics(ICACCI). Udupi, India: IEEE Press, 2017: 55-60.
- [11] Schmid P J. Dynamic mode decomposition of numerical and experimental data[J]. Journal of Fluid Mechanics, 2010, 656: 5-28.
- [12] 周杰, 袁梅, 唐登洪. Von-Mises 分布下椭圆散射信道建模[J]. 北京邮电大学学报, 2017, 40(2): 36-42.  
Zhou Jie, Yuan Mei, Tang Denghong. The elliptical scattering channel modeling based on Von-Mises distribution[J]. Journal of Beijing University of Posts and Telecommunications, 2017, 40(2): 36-42.
- [13] Flandrin P, Rilling G, Concalves P. Empirical mode decomposition as a filter bank[J]. IEEE Signal Processing Letters, 2004, 11(2): 112-114.
- [14] Kopsinis Y, McLaughlin S. Development of EMD-based denoising methods inspired by wavelet thresholding[C]//IEEE Transactions on Signal Processing. Manchester: IEEE Press, 2014: 1351-1362.
- [15] Yang Zhijing, Jiang Jianmin, Yang Lihua, et al. A new bidimensional EMD algorithm and its applications[C]//2014 9th International Symposium on Communication Systems, Networks & Digital Sign (CSNDSP). Manchester: IEEE Press, 2014: 152-155.