

基于堆栈稀疏自编码器和微动特征的身份认证技术

袁延鑫, 孙 莉, 张 群

(空军工程大学信息与导航学院, 西安, 710077)

摘要 从人体目标雷达回波数据中提取可分性较好的微动特征是实现目标分类的关键。针对传统谱图结构特征无法对体型相似的人体目标精细识别,提出了基于堆栈稀疏自编码器的人体身份认证方法。首先构造堆栈稀疏自编码器网络,利用人体微动数据进行无监督预训练,在不同层提取人体微动特征,然后将得到的特征输入 softmax 分类器进行有监督训练,用交叉验证调整网络参数,最后用训练好的网络进行人体目标分类。在不同人走路实测数据集上,3 人平均识别率达到了 83%,优于提取谱图结构特征分类的方法。

关键词 堆栈稀疏自编码器;特征提取;微动特征;身份认证

DOI 10.3969/j.issn.1009-3516.2018.04.009

中图分类号 TN957.51 **文献标志码** A **文章编号** 1009-3516(2018)04-0048-06

Authentication Technology via Stack Sparse Autoencoder and Micro-Motion Feature

YUAN Yanxin, SUN Li, ZHANG Qun

(Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract: Extracting micro-motion features from human radar echo data is a key to human target classification. Aimed at the problem that the traditional spectrum structure is hard to realize the fine recognition of similar body size, a method of human body identity authentication based on stack sparse autoencoder is proposed. First of all, this paper constructs a stack-sparse self-encoder network, performs unsupervised pre-training by using human micro-motion data, and extracts human micro-motion features at different layers. Then the paper inputs the features into the softmax classifier for supervised training, and adjusts the network parameters by cross-validation. Finally, the paper uses the trained network for human target classification. The average recognition rate of 3 people on the measured data set of different people reaches 83%, and is better than that by the method of extracting spectral structure feature classification.

Key words: stack sparse autoencoder; feature extraction; micro-motion feature; identity authentication

雷达具有可以穿透伪装、不受天气和光线等影响、能够实现远距离识别等优势,近年来在理论研究和实际应用中得到越来越多的关注^[1-3]。所谓“微多普勒效应”,是指雷达目标或目标结构中的旋转、振动、摆动等微小运动对雷达回波信号产生多普勒频率调制的物理

现象^[4-5],被认为是目标的独特特征。人体微动特征包含了人体运动状态和身体姿态的有效信息,通过分析人体回波微多普勒效应并提取相应的微动特征,可为人体目标的认证与识别提供重要依据^[6-8]。

文献[9]对人体雷达回波做时频变换,在谱图中

收稿日期: 2017-12-13

基金项目: 国家自然科学基金(61701531);航空科学基金(20121996016);陕西省统筹创新工程特色产业创新链项目(2015KTTSGY0406)

作者简介: 袁延鑫(1993—),男,山东潍坊人,硕士生,主要从事雷达信号处理研究。E-mail:yyx520sar@163.com

引用格式: 袁延鑫,孙莉,张群. 基于堆栈稀疏自编码器和微动特征的身份认证技术[J]. 空军工程大学学报(自然科学版), 2018, 19(4): 48-53. YUAN Yanxin, SUN Li, ZHANG Qun. Authentication Technology via Stack Sparse Autoencoder and Micro-Motion Feature[J]. Journal of Air Force Engineering University (Natural Science Edition), 2018, 19(4): 48-53.

提取了躯干多普勒频率、多普勒信号的总带宽、总多普勒的偏移量、微多普勒的带宽、多普勒信号强度的归一化标准偏差(STD)、肢体运动的周期等 6 个特征对人行走、跑步、持枪、爬行、静坐、原地打拳、前进中打拳等 6 类人类活动进行了分类识别。文献[10]基于目标的物理特征,使用多普勒雷达进行人体探测,提取谱图中的肢体运动的频率、目标步幅、多普勒信号的带宽、多普勒信号强度的归一化标准偏差 4 个特征,对人、狗、汽车、自行车 4 类目标做了分类识别。文献[11]提取了躯干的多普勒频率、躯干多普勒频率的方差、躯干多普勒波形的振荡频率对同一人体目标跑步和走路姿态进行了分类识别。从谱图中提取的结构特征,可以实现目标差别明显(比如人、车)的分类问题,但是对于相近目标(比如不同人体目标),这些特征可分性和差异性不强,无法用于身份认证或者人体步态特征的精细识别,而一些细微特征比如四肢的协调性、重心的晃动等无法用谱图中信息表示,因此需要探求新的特征学习的方法。

自动编码器是神经网络中一种重要的无监督学习方式,能够提取数据非线性特征,因而被广泛应用到多种领域^[12]。堆叠多个自动编码器组成堆栈自动编码器,堆栈自动编码器能够提取目标数据更深层次的特征,挖掘数据本质信息。文献[13]将加入平均像约束的堆栈自编码器应用于雷达高分辨距离像识别中,提高了识别精度。文献[14]将降噪稀疏自编码器应用到静态手势识别中,文献[15]将降噪稀疏自编码器用于指纹的特征提取与识别,都取得了较好的实验效果,证明了该方法的有效性。

为了解决人体目标识别中精细特征提取问题,获取目标本质微动特征信息,提高识别精度。本文提出基于堆栈稀疏自动编码器的雷达目标识别方法,学习数据的深层微动特征表达并设置标签,然后输入到 softmax 分类器中进行训练,对目标进行认证识别。

1 基于堆栈稀疏自编码器的特征提取原理

1.1 自编码器

自编码器是神经网络的一种,它基于深度学习理论,是一种无监督的特征学习方法,经过训练后能尝试将输入复制到输出^[16-17]。自编码器的内层可以有效抽取原始数据的内在表达。自编码器内部有一个隐藏层 h ,可以产生编码来表示输入信号。自编码器可以看作由 2 个部分组成:一个由函数 $h=f(x)=f'(Wx+b)$ 表示的编码器,一个由函数 $r=g(h)=g'(W'h+b')=g'(W'f(x)+b')$ 表示的解码

器。其中 $\{W, W'\}$ 是权值系数, $\{b, b'\}$ 是偏置系数, f', g' 是激活函数。其学习策略可以抽象成一个最小化重构误差的凸优化问题: $\min \sum_i^n \|x_i - r_i\|^2$, 即最小化重构和输入的均方误差。如果输出值能够对它的原始输入进行良好重构,那么就认为编码值 h 保留了原始数据所含有的大部分信息^[18]。其一般结构如图 1 所示。 x 是输入数据,通过编码 h 将输入 x 重构成 r 。

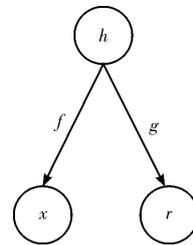


图 1 自编码器结构图

Fig. 1 Autoencoder structure

1.2 堆栈稀疏自编码器

当隐藏层神经元数目较多时,可以通过给自编码神经网络施加一些其他的限制条件来发现输入数据中的特征。稀疏正则化的自编码器是在代价函数中加入稀疏惩罚 $\Omega(\rho)$,使得大部分神经元处于被抑制状态,即被 sigmoid 函数激活是输出接近 0。稀疏自编码器可以学到训练数据集的独特统计特征。

$$\Omega(\rho) = \lambda \sum_{i=1}^n KL(\rho_0 \parallel \bar{\rho}_i) \quad (1)$$

式中: λ 为稀疏惩罚权重; $\sum_{i=1}^n KL(\rho_0 \parallel \bar{\rho}_i)$ 为 1 个以 ρ_0 为均值和 1 个以 $\bar{\rho}_i$ 为均值的 2 个是随机变量之间的相对熵。

$$\sum_{i=1}^n KL(\rho_0 \parallel \bar{\rho}_i) = \sum_{i=1}^n \left(\rho_0 \lg \frac{\rho_0}{\bar{\rho}_i} + (1 - \rho_0) \lg \frac{1 - \rho_0}{1 - \bar{\rho}_i} \right) \quad (2)$$

式中: n 为隐层单元数; ρ_0 为目标稀疏值; $\bar{\rho}_i$ 为所有训练样本在第 i 个隐层单元的平均响应值,它取决于隐层权值系数 W 和偏置系数 b 。相对熵可以测量 2 个分布之间的差异。当 $\rho_0 = \bar{\rho}_i$ 时 $KL(\rho_0 \parallel \bar{\rho}_i = 0)$, 并且随着 ρ_0 与 $\bar{\rho}_i$ 之间的差异增大而逐渐增大。通过最小化稀疏惩罚使得 $\bar{\rho}_i$ 接近提前设定的 ρ_0 , 从而达到网络的稀疏目的。

堆栈稀疏自编码器是由多个稀疏自编码器堆叠形成^[19]。每次训练只做 1 层,每一层都作为一个自编码器,前一层网络的特征作为后一层网络的输入,逐层进行训练。输入原始数据 x , 训练第 1 层稀疏自编码器,首先学习得到数据的第 1 阶特征表示 h_1 , 然后将该特

征作为下一个稀疏自编码器的输入,得到第2阶特征表示 h_2 ,依次类推,可以得到 n 阶特征表示 h_n 。这样获得输入数据更深层次特征,其一般结构见图2。

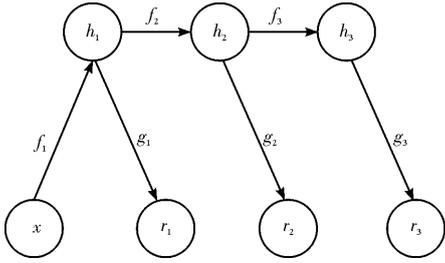


图2 堆栈稀疏自编码器结构图

Fig.2 Stack sparse autoencoder structure

1.3 softmax 分类器原理

softmax 分类器用于解决多分类问题。数据的类别标签 y 可以取 k 类不同的值。给定某一训练集 $\{(x(1), y(1)), \dots, (x(m), y(m))\}$, $y(i) \in \{1, 2, \dots, k\}$ 。对于输入 x ,通过 softmax 分类器估算属于类别 j 的概率值 $p(y=j|x)$, $j=1, 2, \dots, k$ 。假设 softmax 函数的输入数据是 k 维度的向量 z ,那么 softmax 函数的输出数据也是一个 k 维度的向量 s 。softmax 函数是一个归一化的指数函数,定义如下:

$$s_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | x^{(i)}, \theta) \\ p(y^{(i)} = 2 | x^{(i)}, \theta) \\ \vdots \\ p(y^{(i)} = k | x^{(i)}, \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \vdots \\ e^{\theta_k^T x^{(i)}} \end{bmatrix} \quad (3)$$

式中: θ_j^T 为模型的参数,通过样本集可以训练模型参数,从而最小化代价函数 $J(\theta) = -\frac{1}{m} [\sum_{i=1}^m y^{(i)} \log h_{\theta}(x^{(i)}) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)}))]$ 。训练完成后,给分类器输入 $x^{(i)}$ 则会输出 k 个概率值,把概率最大的类别 $\arg \max_j p(y=j|x)$ 作为目标的估计类。

2 特征提取及目标分类实验步骤

2.1 采集数据

实验所用的原始数据是在微波暗室中采集的人体雷达回波。采集设备包括矢量射频信号源、射频电路、实时信号分析仪、收发天线等。矢量射频信号源发射载频为 10 GHz 的单频连续波信号,通过射频电路到发射天线照射被采集者,接收天线收到回

波信号显示在示波器是并对原始数据存储,见图3。

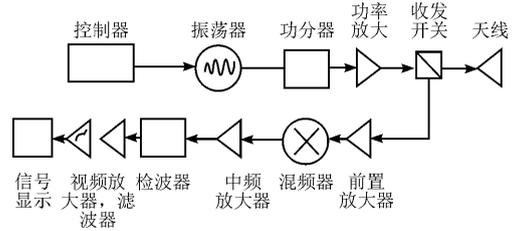


图3 信号采集系统实验原理图

Fig.3 Microwave darkroom data acquisition scene

实验采集了6个不同人的数据,他们性别、体型、走路习惯都存在不同的差异见表1。示波器采集的人体雷达回波信号时域见图4。

表1 学生身高体重分布

Tab.1 Students' height and weight distribution

学生编号	身高/cm	体重/kg	腿长/cm	臂长/cm
1	178	74	106	69.5
2	170	62	102	65.0
3	170	75	98	68.0
4	184	75	112	73.0
5	175	65	104	68.0
6	172	60	100	68.0

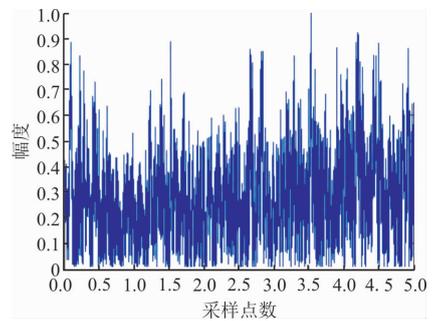


图4 雷达回波时域信号

Fig.4 Radar echo time domain signal

2.2 特征提取及目标分类

为了提取人体的微动特征,首先对采集的人体雷达回波数据进行短时傅里叶变换。图5是不同人的时间-频率图像。

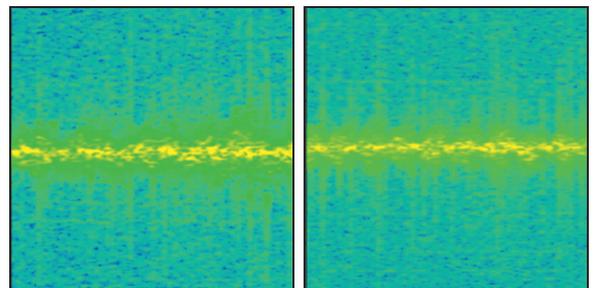


图5 人体微多普勒谱图

Fig.5 Human micro-doppler spectrum

将短时傅里叶变换的数据输入堆栈稀疏自编码

器,逐层训练提取特征,然后输入分类器,见图6。

具体步骤为:

Step 1 预处理数据集,对采集的人体雷达回波时频信号每 1.5 s 取一段数据,间隔 0.5 s 滑动选取,每个目标共得到样本 270 个。

Step 2 对样本分别添加 -20 dB、-25 dB、-30 dB 的高斯噪声,扩充数据集共得到样本 1 080 个。

Step 3 设定编码器层数 m 、隐层神经元数目 n_i 、稀疏惩罚权重 λ ,稀疏性参数 ρ 。

Step 4 超参数调整,寻找一个分类效果比较好的超参数设置。

Step 5 用 1 080 个数据训练第 1 层自编码器,将第 1 层编码结果作为输入训练第 2 层自编码器,逐层训练学习深度特征,完成无监督训练。

Step 6 将学到的其中 800 个数据特征及标签输入 softmax 分类器,进行有监督微调。用在 280 个数据学到的特征及标签测试分类精度。

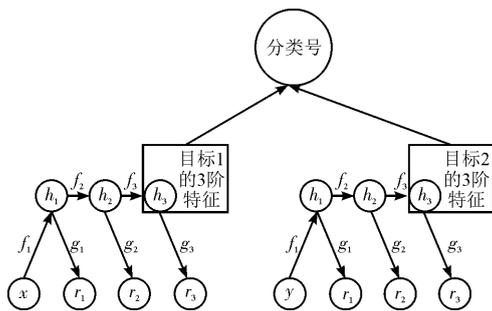


图6 特征学习及分类过程

Fig. 6 Feature learning and classification process

3 基于堆栈稀疏自编码器的目标分类实验结果分析

实验采用微波暗室采集的 6 人雷达回波数据,每个样本频率范围是 -50~50 Hz,频率采样间隔 2.5 Hz,时间采样间隔 100 ms。本文中原始输入特征为 600 维,因此输入层的节点数目为 600,输出层节点数目根据分类任务不同而定。为防止网络“过拟合”,网络隐层神经元的数目与输入层和输出层数目之和相当比较合适^[20]。因此需要设隐层数目,隐层的神经元的数目分别为 640、320、160。

本实验运行是在 ubuntu 操作平台上,主频 2.8 GHz,运行内存 8 G,没有使用 GPU 参与运算,训练迭代 2 000 次,用时 3 min。

3.1 网络参数对试验结果影响分析

稀疏性参数 ρ 通常是一个接近于 0 的较小的值,使网络能获得更好的泛化能力。稀疏惩罚权重参数 λ 用于控制稀疏性惩罚因子的权重, λ 越大网

络越稀疏。设置参数 $\rho=0.1, \lambda=1.5$,对于网络结构和参数的选择,将相同的 3 阶特征数据输入网络,测试 3 人识别准确率,改变参数 λ, ρ 并记录准确率,见表 2。

通过分析表 2 数据可知,自编码器超参数对网络性能有较大影响。分类准确度随 λ 和 ρ 变化而变化,2 个参数变化具有一定相关性,共同决定了网络的稀疏性。当 $\lambda=1.0, \rho=0.3$ 时,网络性能较好,识别精度最高达到了 79%。目前参数调整依靠手动优化,对不同的试验和样本需要重新调试。

表 2 不同参数自编码器识别准确率

Tab. 2 Comparison of different parameters autoencoder recognition accuracy %

参数	$\rho=0.1$	$\rho=0.2$	$\rho=0.3$	$\rho=0.4$
$\lambda=0.5$	63	66	71	74
$\lambda=1.0$	65	73	79	71
$\lambda=1.5$	53	77	72	67
$\lambda=2.0$	71	67	62	65

3.2 自编码器与提取谱图特征方法对比试验

本文通过与文献[6]中所提取的 3 种谱图特征:躯干多普勒、多普勒信号带宽、肢体运动的周期进行了对比。分别把 2 种方法提取到的特征作为输入训练分类器,记录准确率。

通过对比表 3、4 中数据可以发现,随着人数增多,自编码器提取的 3 阶特征的分类准确率比谱图结构特征效果更好。提取谱图结构特征分类的方法准确率下降幅度较大,而自编码器提取的特征下降幅度较小,体型相似的人群在某些谱图特征上差异很小,而自编码器学习的是整体特征。而且随着自编码网络层数的加深,提取到更本质的特征,识别准确率不断提高。

表 3 谱图特征识别准确率

Tab. 3 Comparison of different spectrum feature recognition accuracy %

	躯干多普勒 频率	多普勒信号 带宽	肢体运动的 周期
2 人分辨率	52	43	53
3 人分辨率	41	33	40

表 4 自编码器特征识别准确率

Tab. 4 Comparison of different feature recognition accuracy %

	1 阶特征	2 阶特征	3 阶特征
2 人分辨率	68	72	80
3 人分辨率	65	69	79

3.3 自编码器不同阶特征对比试验

由表 5 可见自编码器提取 1、2、3 阶特征联合使

用的分类准确率比单独用3阶特征效果更好,在特征学习过程中,不可避免会造成信息的丢失,低阶特征更丰富但抽象程度低,高阶特征抽象程度高但丢失信息量更多,再把每层学到的特征联合起来,实现特征互补,实现了更高的分类准确率。

表5 自编码器不同特征识别准确率对比

Tab.5 Autoencoder of different feature recognition

	accuracy		%
	3阶特征	1,3阶联合特征	1,2,3阶联合特征
2人分辨率	80	85	88
3人分辨率	79	82	83

3.4 自编码器抗噪性能试验

为进一步检验方法的鲁棒性,给2人数据添加高斯白噪声然后对比2种方法,结果见图7。

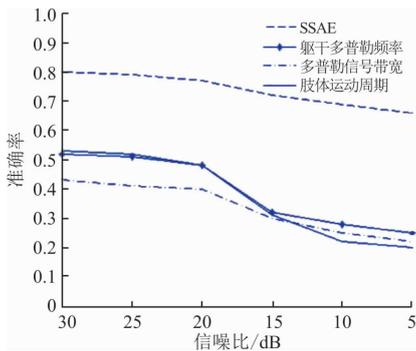


图7 噪声条件下准确率对比

Fig.7 Accuracy comparison under Gaussian noise

随着背景噪声的增加,提取谱图结构特征的方法准确率下降幅度较大,在信噪比为5 dB时,利用躯干多普勒频率分类准确率只有26%,而自编码器提取特征的方法虽然准确率有所下降,但仍有69%的准确率,说明堆栈自编码器具有更好的抗噪性能。

4 结语

人体微动特征是识别人体的重要特征,本文利用堆栈稀疏自编码器的特征表达能力,成功从雷达回波数据集提取到可区分的人体微动特征,解决了体型相似人群谱图特征可分性不强的问题,使用softmax分类器对所学特征进行分类,实现了较高的准确率,并具有较好的抗噪性能,实验证明了方法的有效性。下一步将研究合适的特征选择算法,开展多特征融合算法研究,进一步提升识别的精细程度。同时构建新的网络结构,寻找自适应网络参数优化算法,提高分类准确率。

参考文献(References):

- [1] YONEL B, MASON E, YAZ I, et al. Deep Learning for Passive Synthetic Aperture Radar[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1):90-103.
- [2] CHEN Z, LI G, FIORANELLI F, et al. Personnel Recognition and Gait Classification Based on Multistatic Micro-Doppler Signatures Using Deep Convolutional Neural Networks[J]. IEEE Geoscience & Remote Sensing Letters, 2018(99):1-5.
- [3] PARK J, JAVIER R J, MOON T, et al. Micro-Doppler Based Classification of Human Aquatic Activities via Transfer Learning of Convolutional Neural Networks[J]. Sensors, 2016, 16(12):1990.
- [4] ZHANG Q, LUO Y, CHEN Y. Micro-Doppler Characteristics of Radar Targets [M/OL]. <http://doi.org/10.1016/C.2115-0-01878-0>.
- [5] CHEN Y J, ZHANG Q, MA C Z, et al. Micromotion Feature Extraction of Radar Target Using Tracking Pulses with Adaptive Pulse Repetition Frequency Adjustment [J]. Journal of Applied Remote Sensing, 2014, 8(1): 083569(1-14).
- [6] CHEN V C. Radar Micro-Doppler Signatures: Processing and Applications[M]. London: The Institution of Engineering and Technology Press, 2014.
- [7] CARAPEZZA E M. Using Convolutional Neural Networks for Human Activity Classification on Micro-Doppler Radar Spectrograms[C]// SPIE Defense Security. 2016:982509.
- [8] LANG Y, HOU C, YANG Y, et al. Convolutional Neural Network for Human Micro-Doppler Classification[C]// European Microwave Conference, 2017.
- [9] KIM Y, LING H. Human Activity Classification Based on Micro-Doppler Signatures Using a Support Vector Machine[J]. IEEE Transactions on Geoscience & Remote Sensing, 2009, 47(5):1328-1337.
- [10] KIM Y, HA S, KWON J. Human Detection Using Doppler Radar Based on Physical Characteristics of Targets[J]. IEEE Geoscience & Remote Sensing Letters, 2014, 12(2):289-293.
- [11] 张翼, 朱玉鹏, 刘峥, 等. 基于微多普勒特征的人体运动辨识[J]. 西南大学学报(自然科学版), 2010, 32(3):156-161.
ZHANG Y, ZHU Y P, LIU Z, et al. Human Motion Identification Based on Micro-doppler Features [J]. Journal of Southwest University(Natural Science Edition), 2010,32(3): 156-161. (in Chinese)
- [12] JIANG X, ZHANG Y, ZHANG W, et al. A Novel Sparse Auto-Encoder for Deep Unsupervised Learning

- [C]// 6th International Conference on Advanced Computational Intelligence of IEEE, 2014:256-261.
- [13] 冯博, 陈渤, 王鹏辉, 等. 基于稳健深度网络的雷达高分辨距离像目标特征提取算法[J]. 电子与信息学报, 2014, 36(12):2949-2955.
FENG B, CHEN B, WANG P H, et al. Feature Extraction Method for Rader High Resolution Range Profile Tavgets Based on Robust Deep Networks[J]. Journal of Electronics & Information Technology, 2014, 36(12): 2949-2955. (in Chinese)
- [14] KUMAR V, NANDI G C, KALA R. Static Hand Gesture Recognition Using Stacked Denoising Sparse Autoencoders[C]// 7th International Conference on Contemporary Computing of IEEE. 2014:99-104.
- [15] SANKARAN A, PANDEY P, VATSA M, et al. On Latent Fingerprint Minutiae Extraction Using Stacked Denoising Sparse AutoEncoders[C]// IEEE International Joint Conference on Biometrics. 2014:1-7.
- [16] TIVIVE F H C, BOUZERDOUM A, AMIN M G. A Human Gait Classification Method Based on Radar Doppler Spectrograms[J]. Eurasip Journal on Advances in Signal Processing, 2010(1):389716.
- [17] ZHANG L, LU Y, ZHANG Z, et al. Sparse Autoencoder with Smoothed\ (l_1) Regularization[J]. Neural Information Processing, 2018, 47(3): 829-839.
- [18] BALDI, P. Autoencoders, Unsupervised Learning, and Deep Architectures [J]. Journal of Machine Learning Research, 2012, 27: 37-50.
- [19] TAO C, PAN H, LI Y, et al. Unsupervised Spectral-Spatial Feature Learning with Stacked Sparse Autoencoder for Hyperspectral Imagery Classification [J]. IEEE Geoscience & Remote Sensing Letters, 2015, 12(12):2438-2442.
- [20] 施彦, 韩力群, 廉小亲. 神经网络设计方法与实例分析[M]. 北京: 北京邮电大学出版社, 2009: 32-108.
SHI Y, HAN L Q, LIAN X Q. Neural Network Design and Case Analysis[M]. Beijing: Beijing University of Posts and Telecommunications Press, 2009: 32-108. (in Chinese)

(编辑: 徐敏)

(上接第 47 页)

- [10] GLEISS R, DESLANDES R M. Simulation of Missile Plumes for Aircraft Store Compatibility Assessments[Z]. AIAA 2005-54.
- [11] SINGH R, BAEDER J D. Direct Calculation of Three-Dimensional Indicial Lift Response Using Computational Fluid Dynamics[J]. Journal of Aircraft, 1997, 34(4):465-471.
- [12] PARAMESWARAN V, BAEDER J D. Indicial Aerodynamics in Compressible Flow-Direct Computational Fluid Dynamic Calculations[J]. Journal of Aircraft, 1997, 34(1):131-133.
- [13] 詹浩, 钱炜祺. 翼型和机翼阵风响应的数值模拟[J]. 空气动力学报, 2007, 25(4):531-536.
ZHAN H, QIAN W Q. Numerical Simulation of Gust Response for Airfoil and Wing[J]. Acta Aerodynamica Sinica, 2007, 25(4):531-536. (in Chinese)
- [14] 任玉新. 计算流体力学讲义[EB/OL]. (2003-07-01) [2017-12-01]. <http://www.docin.com/p-28135837.html>.
- REN Y X. Computational Fluid Mechanics[EB/OL]. (2003-07-01)[2017-12-01]. <http://www.docin.com/p-28135837.html>. (in Chinese)
- [15] BALLHAUS W F, GOOR JIAN P M. Computation of Unsteady Transonic Flows by the Indicial Method [J]. AIAA Journal, 1978, 16(2): 117-124.
- [16] AHMAD J U, SHANKS S P, BUNING P G. Aero-dynamics of Powered Missile Separation from F/A-18 Aircraft[Z]. AIAA-93-0766.
- [17] FAA. FAR25 Airworthiness Standards; Transport Category Airplane[S]. Seattle: FAA, 2007.
- [18] 符文星, 尚妮妮, 常晓飞, 等. 离散阵风幅值计算的方法研究 [J]. 西北工业大学学报, 2014, 32(5): 822-827.
FU W X, SHANG N N, CHANG X F, et al. A New Method for Calculating Magnitude of Wind Gust [J]. Journal of Northwestern Polytechnical University, 2014, 32(5):822-827. (in Chinese)

(编辑: 徐敏)