

DOI:10.11918/j.issn.0367-6234.201706021

栈式降噪自编码器在波形单元识别中的应用

陈维高, 朱卫纲, 唐晓婧, 贾 鑫

(航天工程大学, 北京 101416)

摘 要: 为提高多功能雷达 (Multi-Function Radar, MFR) 波形单元的识别准确率和鲁棒性, 提出一种栈式降噪自编码器 (Stacked Denoising Autoencoders, SDAE) 与支持向量机 (Support Vector Machine, SVM) 相结合的波形单元识别方法. 首先摒弃传统依赖脉冲序列分析技术对 MFR 信号进行处理的方法, 通过分析波形单元结构并借助参数间的联合变化特征, 提出一种 MFR 波形单元分段识别模型, 将传统对脉冲序列的识别转化为对 MFR 波形单元的识别; 然后在该模型的基础上引入 SDAE, 对训练样本数据、SDAE 隐含层神经元节点进行加噪处理, 并利用这些加噪后的样本数据训练优化 SDAE 网络模型, 提取出样本数据的深层稳健特征; 最后引入 SVM 算法, 借助 SDAE 挖掘出的样本深层特征, 实现 SVM 模型的优化, 得到最终的波形单元识别模型 (SDAE-SVM). 仿真实验表明: 提出的波形单元识别方法在相同样本数目和测试误差的条件下, 与 SVM 算法相比, 能够取得较高的识别准确率, 具备更优越的识别效果. 证实 MFR 波形单元识别模型是有效的, 且通过 SDAE 网络的引入, 使得 SDAE-SVM 方法能够自主地挖掘原始信号的深层特征, 提高波形单元识别的鲁棒性和准确率.

关键词: 多功能雷达; 波形单元; 深度学习; 降噪自编码器; 支持向量机

中图分类号: TN958.92

文献标志码: A

文章编号: 0367-6234(2018)11-0094-07

The application of stacked denoising autoencoders in waveform unit identification

CHEN Weigao, ZHU Weigang, TANG Xiaojing, JIA Xin

(Space Engineering University, Beijing 101416, China)

Abstract: To improve the accuracy and robustness of the Multi-Function Radar (MFR) waveform unit identification, a waveform unit identification method combining Stacked Denoising Autoencoders (SDAE) with Support Vector Machine (SVM) is proposed. The traditional MFR signal processing method relying on pulse sequence analysis is abandoned. A MFR waveform unit segmental identification model is proposed by analyzing the structure of waveform unit and the union variation characteristics of parameters. By using this model, the traditional identification of pulse sequences can be converted to the identification of MFR waveform unit. On the basis of this model, SDAE algorithm is introduced. The training sample data and SDAE hidden layer nodes are processed by noise adding. Using the training sample data, the SDAE network model is trained, and the deep robust feature of the sample data is extracted. Lastly, SVM algorithm is introduced. By using the deep feature of the SDAE output, the SVM model is optimized, and the final waveform unit identification model can be obtained. Simulation results show that under the same condition of sample number and test error, the proposed method can achieve high recognition accuracy, and has better identification results than SVM algorithm. The MFR waveform unit segmental identification model is verified. Besides, through the introduction of SDAE, the proposed SDAE-SVM method can autonomously dig up the deep feature of original data, and improves the robustness and accuracy of the waveform unit identification.

Keywords: Multi-Function Radar (MFR); waveform unit; Deep Learning; Stacked Denoising Autoencoders (SDAE); Support Vector Machine (SVM)

近年来,随着 MFR 在军事上的广泛应用,促使对 MFR 的识别^[1]、状态跟踪及预测技术^[2]成为电子情报侦察领域研究的热点,波形单元作为 MFR 信号的基本构成,其识别的优劣决定后续对 MFR 状态跟踪、预测的准确度,对 MFR 的威胁和态势感知具

有重要意义.

传统思想将波形单元识别定位为脉冲序列分析技术^[3],大多从单一特征、匹配等方面进行研究. Kauppi J. 等^[4]在无先验知识条件下利用脉冲重复间隔 (Pulse Repetition Interval, PRI) 特征对波形单元进行提取,但其前提是每个波形单元只具备一种 PRI 特征且相邻波形单元的 PRI 特征互不相同. 刘海军等^[5]利用波形库、脉冲到达时间和编码序列三级匹配的思想不断地提高匹配精度,实现波形单元

收稿日期: 2017-06-21

作者简介: 陈维高 (1990—), 男, 博士生

贾 鑫 (1958—), 男, 教授, 博士生导师

通信作者: 贾 鑫, 13910413166@139.com

的提取,但其归根结底为匹配技术,存在着鲁棒性不强的问题。

2006 年 Hinton 等^[6]通过构建深层网络结构提取出较常规网络更有价值的特征信息,从而引发研究深度学习的热潮。与此同时,栈式自编码器(Stacked Autoencoders, SAE)应运而生,常用于其它深度学习框架的初始化阶段,获得显著的成果^[7]。随后 Pascal 等^[8]提出“从加噪的输入信号中重构出原始输入信号能够获得更好的特征表述”理论,进而构建 SDAE,提取出更为鲁棒的特征信息。

综上所述,一方面为提高 MFR 波形单元的识别准确率和鲁棒性,另一方面为引入优异的模式识别算法来解决波形单元识别问题,首先通过分析波形单元的结构特点,提出一种波形单元分段识别模型;然后在该模型的基础上,针对 MFR 波形单元识别问题,结合 SDAE 深度特征提取及 SVM 全局最优、泛化能力强的优点,提出一种基于 SDAE 与 SVM 相结合的 MFR 波形单元识别方法(SDAE-SVM)。

1 波形单元分段识别模型构建

1.1 波形单元分析

由于 MFR 的多功能特性,为最大限度地发挥 MFR 的系统性能,实际中需要针对所面临的各种环境及目标特点设计相应的波形单元,并存储在称为“波形库”的存储器中^[9]。波形单元是指为提取特定的目标信息,或实现某种能力,而对有限脉冲的一个固定优化排列^[10],由内嵌脉冲列和空载时间两部分构成,其结构见图 1。




图 1 波形单元结构

Fig.1 Waveform unit structure

图 1 展示由两组内嵌脉冲列和两组空载时间构成的波形单元,其中 u 代表内嵌脉冲列, v 代表空载时间。一般地,一个波形单元内可拥有多组内嵌脉冲列和空载时间,各个内嵌脉冲列具备相互独立的参数信息,即独立的参数值和调制样式,同一内嵌脉冲列的参数调制样式保持不变;空载时间的时长按需求设定,并可分布在波形单元的起始端、中间区域及末端。

1.2 波形单元参数表述

为充分利用信号参数信息实现波形单元的识别,首先需要对其进行参数表述。在前期研究中^[11],

为反映 MFR 运行机制和全面详尽描述信号特征,构建任务、状态、参数的 MFR 层级模型,见图 2,其中 F 代表 MFR 所执行的任务、 P 代表内置的状态、 ω 则代表波形单元。




图 2 MFR 辐射源层级模型

Fig.2 Hierarchical modeling of MFR emitter

参照文献[12]对 MFR 层级模型的具体分析。波形单元 ω_i 可利用集合 H_{ω_i} 表示, $H_{\omega_i} = \{M^{\omega_i}, T^{\omega_i}, V^{\omega_i}, N^{\omega_i}\}$, 包含 4 组描述信息。

M 为各个参数的描述信息,通过分析总结信号参数的变化规律,可将其描述为 4 种: $M = x_0$, 参数值固定不变的描述(包含空集); $M = [x^L, x^U]$, 参数值为区间类型的描述; $M = [x_0, x_1, \dots]$, 参数值为枚举序列的描述; $M = f(x)$, 参数值为函数类型的描述。

T 为参数调制类型,利用常数 0, 1, 2... 表述,不同参数的 T 具备不同意义,0 代表无调制。例如常规脉冲描述字 PRI、RF、PW, 各个参数的调制类型可表示为: PRI: 1 固定, 2 参差, 3 组变, 4 抖动, 5 渐变, 6 正弦调制; RF: 1 固定, 2 捷变, 3 组变, 4 跳变; PW: 1 区间, 2 多脉宽组合, 3 抖动。

V 代表波形单元的空载时间,按其在波形单元中的分布位置进行表述,其中分布在起始端和末端的用 D 第一个和最后一个数据表述,如果某个位置不存在空载时间,则用常数 0 表述。

N 代表波形单元内嵌脉冲列的脉冲个数,在该段脉冲序列中,所有参数均保持其各自的调制样式不变。

1.3 识别模型构建

波形单元分段识别基本原理简述如下:

1) 训练集初始化。已知 MFR 内置波形单元训练集 $X = \{(x_1, y_1, z_1), \dots, (x_i, y_i, z_i), \dots, (x_p, y_p, z_p)\}$, $i = 1, 2, \dots, p$, 其中 $x_i \in R^n$, $y_i \in \{1, 2, \dots, k\}$, $z_i \in \{1, 2, \dots, m\}$ 分别代表第 i 组训练数据的内嵌脉冲列参数集、内嵌脉冲列标签和波形单元标签, p, n, k, m 分别指代训练样本总数、特征维度、内嵌脉冲列总数及波形单元总数。

2) 识别算法优化。令 f 指代机器学习、深度学习

等识别算法,首先对波形单元库 X 进行训练 $f(X)$, 得到优化后的识别模型 f' .

3) 内嵌脉冲列识别. 利用模型 f' 对内嵌脉冲列集 $X' = \{x'_1, x'_2, \dots, x'_q\}$ 进行识别 $f'(X')$, 得到内嵌脉冲列和波形单元的标签 $Y' = \{y'_1, y'_2, \dots, y'_q\}$, $Z' = \{z'_1, z'_2, \dots, z'_q\}$.

任选波形库中某一波形单元 $\omega_j, j = 1, 2, \dots, m$, 设包含 k'_u 个 u (对应的训练样本标签为 $\{y_{j1}, y_{j2}, \dots, y_{jk'_u}\}$), k'_v 个 v , 选取 $Z' = j$ 的数据集 $\{X'_j, Y'_j, Z'_j\}$. 如果存在 $y'_{j1}, \dots, y'_{jk'_u} \in Y'_j$ 使得 $y'_{j1} = y_{j1}, \dots, y'_{jk'_u} = y_{jk'_u}$, 则标签识别成功, 认为数据集 $\{X'_{j1}, Y'_{j1}, Z'_{j1}\}, \dots, \{X'_{jk'_u}, Y'_{jk'_u}, Z'_{jk'_u}\}$ 所描述的 k'_u 组脉冲列, 分别包含多组相应的内嵌脉冲列 $u_{j1}, \dots, u_{jk'_u}$, 并令脉冲的标签为 j , 归属为波形单元 ω_j 的脉冲.

4) 波形单元重构. 当 $k'_u = 1$, 即 ω_j 只包含一个 u 时, 对于识别出的脉冲列 ζ_{j1} , 按照 ω_j 中的 V^{ω_j} 即可重构出 ω'_j ; 当 $k'_u \geq 2$, 即 ω_j 包含多个 u 时, 对于识别出的 k'_u 组脉冲列 $\zeta_{j1}, \dots, \zeta_{jk'_u}$, 先按照 TOA 综合排序, 然后利用 ω_j 中的 V^{ω_j} 恢复出起始端、末端的空载时间, 重构出 ω'_j . 为下一步对 MFR 功能状态的识别和预测, 需要对同一 MFR 的所有脉冲列按 TOA 排序, 得到该 MFR 的全脉冲序列, 在波形单元识别和重构基础上, 即可恢复出波形单元在 MFR 状态层上的分布.

2 基于 SDAE 的无监督学习

2.1 基本栈式自编码器

SAE 是一种具备编码和译码对称结构的多层前馈网络, 通过重构输入数据, 最小化重构误差来实现无监督学习和非线性特征提取. 可将 SAE 理解为堆叠多个隐层的 AE, 网络结构通常关于中间层对称, 见图 3.




图 3 SAE 的网络结构

Fig.3 Network structure of SAE

图 3 展示包含 $2r - 1$ 个隐含层的 SAE 网络结构, 其输入、输出层各包含 m 个神经元, 输入、输出向量分别表示为 $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$, $\mathbf{o} = (o_1, o_2, \dots, o_m)^T$; 对于第 k 个隐含层, 包含 n_k 个神经元 ($k = 1, 2, \dots, 2r - 1$), 且 $n_k = n_{2r-k}$ 权重矩阵

$$\begin{cases} \mathbf{W}^1 = (w_{ij}^1)_{n_1 \times m}; \\ \mathbf{W}^k = (w_{ij}^k)_{n_k \times n_{k-1}}, \quad 2 \leq k \leq 2r - 1; \\ \mathbf{W}^{2r} = (w_{ij}^{2r})_{m \times n_{2r-1}}. \end{cases} \quad (1)$$

分别代表输入与第 1 个隐层、第 $k - 1$ 个隐层到第 k ($2 \leq k \leq 2r - 1$) 个隐层、第 $2r - 1$ 隐层到输出的权重矩阵, $\mathbf{b}^1, \mathbf{b}^k, \mathbf{b}^{2r}$ 分别为相应的偏置. 则 SAE 的各层神经元的输出为

$$\begin{cases} \mathbf{h}^1 = \sigma_1(\mathbf{W}^1 \mathbf{x} + \mathbf{b}^1); \\ \mathbf{h}^k = \sigma_k(\mathbf{W}^k \mathbf{h}^{k-1} + \mathbf{b}^k), \quad 2 \leq k \leq 2r - 1; \\ \mathbf{o} = \sigma_{2r}(\mathbf{W}^{2r} \mathbf{h}^{2r-1} + \mathbf{b}^{2r}). \end{cases} \quad (2)$$

SAE 通常利用反向传播 (Backpropagation, BP) 算法调整优化参数, 寻找网络收敛的极小点. 设存在 N 个训练样本 $\mathbf{x}^{(l)}$ ($1 \leq l \leq N$), $\mathbf{o}^{(l)}$ 为相应的网络输出, 则整体的代价函数可表示为

$$J_{x,o}(\mathbf{W}, \mathbf{b}) = \left[\frac{1}{N} \sum_{l=1}^N \left(\frac{1}{2} \|\mathbf{o}^{(l)} - \mathbf{x}^{(l)}\|^2 \right) \right] + \frac{\lambda}{2} \|\mathbf{W}\|^2. \quad (3)$$

其中右侧第一项为输入、输出的均方差项, 第二项为防止过度拟合, 对权重衰减进行的约束, λ 为权重衰减系数. 通过随机梯度下降、Momentum、Adam (Adaptive Moment Estimation) 等优化算法求解式 (3) 的最小化 $\arg\min_{\mathbf{W}, \mathbf{b}} J_{x,o}(\mathbf{W}, \mathbf{b})$, 即可按照学习速率 η 对网络参数进行更新. 待参数优化结束, 去除 SAE 的译码网络, 即可获得反映数据本质的非线性特征.

2.2 栈式降噪自编码器

SDAE 的基本思想是利用栈式自编码器从加噪的输入中重构出原始的、未受污染的输入, 从而学习到更稳健鲁棒的深层表达、挖掘出更有意义的分布特征^[8]. 例如单隐层降噪自编码器 (Denoising Autoencoders, DAE), 其基本原理见图 4.




图 4 DAE 原理框图

Fig.4 Functional block diagram of DAE

图 4 中首先对初始输入 x 随机加入噪声, 得到加噪后的输入 $\tilde{x}$; 然后按照常规自编码器对 $\tilde{x}$ 进行编码、译码映射, 得到输出 $\tilde{o}$; 最后利用 x 和 $\tilde{o}$ 构建代价函数 $J_{x,\tilde{o}}(W,b)$, 进而通过优化算法获得收敛的网络。需要注意的是, DAE 与 AE 都是通过最小化输出对输入 x 的重构损失来进行网络优化的, 但 DAE 的输出 $\tilde{o}$ 是由 $\tilde{x}$ 产生的, 这就迫使 DAE 网络在噪声条件下学习更为稳健鲁棒的特征表达。

针对 MFR 波形单元识别的应用场景, 将加噪处理分为训练样本加噪和隐含层加噪两部分, 分别指对波形库中的训练样本、隐含层神经元节点加入偏离误差 (Error Deviation Level, EDL) α 、 β 的过程, 其中 $EDL = |\xi_i/x_i| \times 100\%$, ξ_i 为误差值, x_i 为参数真实值。

3 SDAE-SVM 波形单元识别

SVM 能够利用核函数非线性映射的方法, 将数据空间不明显的特征在高维特征空间中放大、提取并清晰的展现出来, 具备全局最优和推广能力强的特点, 结合 SDAE 和 SVM 的优势, 提出一种 SDAE-SVM 波形单元识别方法, 其流程见图 5。

隐含层权值和偏置, 达到规定的迭代次数或损耗后, 即可剔除译码器和加噪过程 (图 5 中虚线所示的进程), 实现网络优化并提取出训练数据的深层稳健特征。

3) SVM 模型优化。首先为实现多分类目的, 对经典的 C-SVM 进行一类对余类的多分类处理; 然后利用提取的深层特征和训练标签进行 k 折交叉验证, 实现 SVM 模型参数的优化。

4) 未知波形单元识别。经过上述运算, 即可得到参数调优后的 SDAE-SVM 收敛网络模型, 进而利用该模型对未知波形单元进行识别。

4 实验结果与分析

为验证 SDAE-SVM 波形单元识别方法的有效性, 共进行 4 组实验。首先模拟生成 MFR 辐射源波形库, 包含 A、B、C、D, 4 部波形单元各异的 MFR, 同时各个波形单元具备参数特征互不相同的内嵌脉冲列, 共计 12 组波形单元和 21 组内嵌脉冲列。

选用 PRI、RF 和 PW 三种常规参数作为识别特征, 波形库的具体信息见表 1。其中 MFR-A 波形单元 ω_1^A 的各组内嵌脉冲列 u_{11}^A 、 u_{12}^A 、 u_{13}^A 中的 PRI 为组变调制样式, 每隔 3 个脉冲变化一次; MFR-C 波形单元 ω_1^C 只含有 1 组内嵌脉冲列 u_{11}^C , 其 RF 与 PW 存在联合变化调制, 每 6 个脉冲共同变化一次; MFR-C 波形单元 ω_3^C 包含的 2 组内嵌脉冲列 u_{31}^C 、 u_{32}^C 中的 RF 为组变调制样式, 每隔 5 个脉冲变化一次。

依据波形单元分段识别的要求, 将表 1 所示的波形库参照波形单元参数表述, 并作为已知训练样本, 进行下列 3 组实验。

4.1 深度特征提取实验

为提取稳健优异的特征, 针对 SDAE 网络深度对其性能的影响进行分析。实验按照表 1 所示的波形库信息进行样本扩充, 每个内嵌脉冲列扩充为 100 个脉冲描述, 共生成 2 100 个脉冲数据。对这些脉冲样本随机排序, 选取前 200 个作为训练样本, 对后 1 900 个脉冲样本参数加入 5% 的 EDL, 作为测试样本。由于训练样本数据量不大, 为提高收敛效率, 进行分批处理, Batch_Size = 100 即将训练样本分为 8 批处理, 每批 100 个。选取 sigmoid 为激活函数, Adam 为 SDAE 优化方法, 令权重衰减系数 $\lambda = 1 \times 10^{-4}$, 初始学习速率 $\eta = 5 \times 10^{-3}$, 迭代 200 次, 并在迭代过程中逐步减小学习速率 $\eta_{\text{next loop}} = \eta \times 0.96$ 。选取径向基 RBF 作为 SVM 的核函数, 设定 SVM 惩罚因子 $C = 10$, 核函数宽度 $g = 2$ 。对训练样本进行加噪处理, 对输入数据和隐含层神经元分别加入 $\alpha = 5\%$ 、 $\beta = 1\%$ 的 EDL。




图 5 SDAE-SVM 波形单元识别流程图

Fig.5 Waveform unit recognition flow of SDAE-SVM

SDAE-SVM 波形单元识别方法主要包括波形库初始化、SDAE 网络优化、SVM 模型优化和未知波形单元识别 4 部分。

1) 波形库初始化。这里的初始化是指将 MFR 内置的训练波形库和分选后的临时未知波形库都参照波形单元参数表述进行描述。

2) SDAE 网络优化。训练过程中首先对输入的波形单元参数向量 x 加噪处理, 得到 $\tilde{x}$, 进而对 $h^1 \sim h^r$ 隐含层节点加噪处理, 得到 $\tilde{h}^1 \sim \tilde{h}^r$, 然后进行编码、译码运算, 与输出 o 构造损失函数 $J(W,b)$, 最小化该损失函数用来优化编码过程中的 $h^1 \sim h^r$

表 1 MFR 波形库信息表
Tab.1 MFR waveform database information

MFR	波形单元	空载时间/ μs	内嵌脉冲列	脉冲重复间隔/ μs		载频/MHz		脉宽/ μs		脉冲个数
				类型	取值	类型	取值	类型	取值	
A	ω_1^A	3 880/11 640/6 360/2 120	u_{11}^A	组变	[1 850,1 880,1 940]	固定	1 236	抖动	52.1 ± 1.5	10
			u_{12}^A	组变	[1 060,1 150,1 100]	固定	1 248	抖动	52.1 ± 1.5	10
			u_{13}^A	组变	[1 200,1 250,1 310]	固定	1 291	抖动	52.1 ± 1.5	10
	ω_2^A	7 296/14 592	u_{21}^A	固定	2 432	固定	4 642	固定	5.5	23
	ω_3^A	1 600/6 291.4/2 097.1	u_{31}^A	滑变	800/850/900/950/1 000	捷变	[3 850,3 903]	固定	39.1	21
			u_{32}^A	抖动	$1\,000\pm5\%$	固定	2 925	抖动	50.6 ± 1.5	23
B	ω_1^B	3 484/10 452	u_{11}^B	固定	1 742	跳变	1 610/1 625/1 640	固定	20.5	10
	ω_2^B	2 250/7 656/2 552	u_{21}^B	固定	1 125	固定	2 331	固定	18.9	8
			u_{22}^B	固定	1 276	固定	2 852	固定	20.3	5
	ω_3^B	3 141.7/9 425.1/8 052	u_{31}^B	抖动	$1\,500\pm5\%$	捷变	[3 751,3 798]	抖动	15.6 ± 1.5	20
			u_{32}^B	固定	1 342	固定	3 398	固定	16.1	7
	ω_4^C	4 200/12 600	u_{11}^C	固定	2 100	组变	2 300/2 400/2 500	多个	130.7/86.4/42.1	19
C	ω_2^C	3 450/10 350/8 982	u_{21}^C	固定	1 497	固定	3 838	固定	12.6	5
			u_{22}^C	固定	1 725	固定	2 931	固定	12.6	6
			u_{31}^C	固定	1 876	组变	3 452/3 508	固定	10.9	11
	ω_3^C	3 752/11 652/3 884	u_{32}^C	固定	1 942	组变	3 452/3 508	固定	10.9	11
			u_{41}^C	抖动	$2\,300\pm5\%$	捷变	[3 322,3 408]	固定	105.6	19
	ω_4^C	4 804.3/14 412.8/	u_{11}^D	参差	307/343/379/398	固定	5 460	固定	2.5	17
D	ω_1^D	614/3 264/1 088	u_{12}^D	固定	544	固定	5 460	固定	3.20	6
			u_{21}^D	抖动	$800\pm5\%$	固定	5 460	固定	7.3	13
	ω_2^D	1 672.1/5 016.4/4 140	u_{22}^D	固定	690	固定	5 4600	固定	1.5	9

设定隐含层层数依次为 {1,2,3,4,5,6,7,8} , 相应的隐含层神经元数目为 {100,200,300,400,500,600,700,800} , 实验中逐步增加 SDAE 的隐含

层层数,利用具备不同隐含层的 SDAE-SVM 方法进行训练和测试,每个层级重复 50 次实验,得到的识别结果见图 6,训练过程的平均时耗见图 7.




图 6 不同隐含层 SDAE-SVM 的识别结果

Fig.6 Recognition results of SDAE-SVM with different hidden layers

图 6(a) 为小提琴图,其轮廓展示实验结果的密度分布,图中的横线代表中位数;图 6(b) 为盒状图,单个盒形标注自上至下依次代表统计的最大值、上四分位、中位数、下四分位和最小值,其中圆形标记代表

离群点. 当隐含层数目从 1~3 逐步增加时,识别准确率的密度分布和中位数也随之提高;当隐含层数目为 3、4 时,识别准确率趋于稳定且达到最高,统计中位数分别为 94.72%、94.78%. 然而从 5~8 层逐渐增加隐

含层层数时,由于训练样本一定,过多的层数和神经元导致网络过拟合,识别效果迅速下降. 图 7 中随着网络深度的增加,SDAE-SVM 的训练时耗呈指数递增,在隐含层为 8 时,其训练时耗达到 17.7 s.




图 7 SDAE-SVM 训练时耗

Fig.7 Time consumption of SDAE-SVM training process

SDAE-SVM 方法的时间复杂度主要包括模型训练和对测试样本识别两部分,其中由于模型训练阶段又包含 SDAE、SVM 两部分的训练优化,因此时间复杂度较高,而测试阶段是在已优化的识别模型基础上进行的,时间复杂度较低. 除隐含层层数外,训练样本、迭代次数及神经元节点数都对网络的训练时耗有较大影响. 为保证取到优异的深度特征,同时兼顾时效性,选取 3 个隐含层的 SDAE-SVM 网络进行后续实验. 此外算法的收敛性与迭代次数相关. 当迭代次数为 50 时,损失函数 $J(W,b) = 4.836 \times 10^{-4}$; 当迭代次数为 200 时,损失函数 $J(W,b) = 4.526 \times 10^{-4}$,随后再增加迭代次数,损失函数虽有下降,但下降极小,并逐渐收敛,因此从时效性上考虑,文中选用迭代次数为 200,进行后续实验.

4.2 训练样本数目对识别性能的影响

为验证 SDAE-SVM 算法在不同训练样本数目条件下的识别性能,利用 SVM、KNN (K-nearest Neighbors)、DTs (Decision Trees)、MNB (Multinomial Naive Bayes) 及 BP (Back Propagation) 神经网络 5 种经典的监督识别方法进行对比实验. 对表 1 的每个内嵌脉冲列分别扩充为 50、100 个脉冲描述,共生成 1 050 个训练样本和 2 100 个测试样本. 样本随机排序,对测试样本参数加入 15% 的 EDL. SDAE-SVM、SVM 的参数与深度特征提取实验设置相同;KNN 的近邻点个数为 30;DTs 利用信息增益为准则;MNB 采用 Lidstone smoothing 优化,平滑参数为 0.9;BP 包含 1 个隐含层,隐含层节点数为 10,优化算法为 Adam,学习速率为 0.5. 依次增加训练样本数目,重复进行 100 次实验,识别结果见图 8.

实验测得的各算法运算时间都随着训练样本的增加而变大,对于 SDAE-SVM 而言,其运算时间从

0.595 s 近似线性增长指 9.73 s,由于在实验过程中测试样本数目不变,其测试阶段的运算时间稳定在 0.21 s 左右,因此该方法的运算量主要在训练阶段且受训练样本数目影响较大. 图 8 中随着训练样本的增多,各个算法的识别准确率都有明显的提高,并趋于收敛. 由于 SDAE-SVM 挖掘底层鲁棒特征,具备更强的泛化能力,因而在各个训练样本条件下都具备较高的识别准确率. 特别地,在训练样本小于 300 的条件下,SDAE-SVM 的优势较为明显,进一步证实该算法的有效性.




图 8 不同训练数目下识别结果对比

Fig. 8 Identification results contrast with different training samples

4.3 测试误差对识别性能的影响

为验证 SDAE-SVM 算法在不同测试误差条件下的识别性能,分别利用 SVM、KNN、DTs、MNB、BP 进行对比实验. 按训练样本数目对识别性能影响实验生成 2 100 个测试样本,并随机选取 200 个训练样本,对 SDAE-SVM 和 SVM 算法进行 3 折交叉验证,分别得到的最佳参数为 $C_{SDAE-SVM} = 20.565$ 1 , $g_{SDAE-SVM} = 0.811$ 1 , $C_{SVM} = 10.023$ 1 , $g_{SVM} = 100.026$ 3 ,其余算法的参数与设置与训练样本数目对识别性能的影响实验相同,依次增加测试样本的 EDL,重复进行 100 次实验,识别结果见图 9.




图 9 不同测试误差下识别结果对比

Fig.9 Identification results contrast with different test samples error

图 9 中当测试样本 $EDL = 0$ 时, SDAE-SVM、SVM 及 DTs 都能取得优异的认识结果,但随着测试样本 EDL 的增加,各个算法的准确率都逐步下降,其中 SDAE-SVM 下降的最为缓慢,且相同 EDL 条件下,其认识准确率最高,进一步证实该算法具备较强的鲁棒性和泛化能力.

5 结 论

1)通过分析 MFR 的运行机制和波形单元结构,充分利用各个特征参数信息,构建波形单元分段识别模型,不仅能够借助成熟的数据挖掘、模式识别方法进行运算,还在波形单元识别的过程中完成对辐射源的识别.

2)结合栈式降噪自编码器的深度特征提取与支持向量机的全局最优,提出一种 SDAE-SVM 波形单元识别方法,能够取得较好的识别效果,具备优异的鲁棒性和泛化能力.

参考文献

- [1] 刘海军,李悦,柳征,等.基于随机文法的多功能雷达识别方法[J].航空学报,2010,31(9):1809
LIU Haijun, LI Yue, LIU Zheng, et al. Approach to multi-function radar identification based on stochastic grammars [J]. Acta Aeronautica et Astronautica Sinica, 2010, 31(9): 1809
- [2] ARASARATNAM I, HAYKIN S, KIRUBARAJAN T, et al. Tracking the mode of operation of multi-function radars [C]// 2006 IEEE Conference on Radar. New York, USA: IEEE Press, 2006: 233-238. DOI: 10.1109/RADAR.2006.1631804
- [3] 刘海军.雷达辐射源识别关键技术研究[D].长沙:国防科学技术大学,2010
LIU Haijun. Researches on identification key technology for radar emitter [D]. Changsha: National University of Defense Technology, 2010
- [4] KAUPPI J P, MARTIKAINEN K, RUOTSALAINEN U. Hierarchical classification of dynamically varying radar pulse repetition interval modulation patterns [J]. Neural Networks the Official Journal of the International Neural Network Society, 2010, 23(10): 1226.

DOI: 10.1016/j.neunet.2010.06.008

- [5] 刘海军,樊昀,李悦,等.多功能雷达建模中的雷达字提取技术研究[J].国防科技大学学报,2010,32(2):91. DOI: 10.3969/j.issn.1001-2486.2010.02.017
LIU Haijun, FAN Yun, LI Yue, et al. Research on extracting of radar words in modeling of multi-function radar [J]. Journal of National University of Defense Technology, 2010, 32(2): 91. DOI: 10.3969/j.issn.1001-2486.2010.02.017
- [6] 马爽,柳征,姜文利.基于幅度变化点检测的多功能雷达脉冲列解析方法[J].电子学报,2013,41(7):1436-1441. DOI: 10.3969/j.issn.0372-2112.2013.07.030
MA Shuang, LIU Zheng, JIANG Wenli. A method for multifunction radar pulse train analysis based on amplitude change point detection [J]. Acta Electronica Sinica, 2013, 41(7): 1436. DOI: 10.3969/j.issn.0372-2112.2013.07.030
- [7] HINTON G E, SSLAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504. DOI: 10.1126/science.1127647
- [8] ERHAN D, BENGIO Y, COURVILLE A, et al. Why does unsupervised pre-training help deep learning [J]. Journal of Machine Learning Research, 2010, 11(3): 625. DOI: 10.1007/978-3-319-24211-8_18
- [9] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion [J]. Journal of Machine Learning Research, 2010, 11(12): 3371. DOI: 10.15760/etd.1549
- [10] TANIZA R, JADIA K, Raju G S N, et al. High density FPGA based waveform generation for radars [C]// 2010 IEEE Radar Conference. Washington, DC, USA: IEEE Press, 2010: 310. DOI: 10.1109/RADAR.2010.5494606
- [11] VISNEVSKI N, KRISHNAMURTHY V, Wang A, et al. Syntactic modeling and signal processing of multifunction radars: a stochastic context-free grammar approach [J]. Proceedings of the IEEE, 2007, 95(5): 1000. DOI: 10.1109/jproc.2007.893252
- [12] 陈维高,贾鑫,朱卫纲,等.基于 HMM 的雷达状态转移估计方法[J/OL]. (2017-02-03) [2017-05-01]. <http://www.cnki.net/kcms/detail/11.2625.V.20170203.1533.002.html>
CHEN Weigao, JIA Xin, ZHU Weigang, et al. The radar state transfer estimation algorithm based on HMM model [J/OL]. (2017-02-03) [2017-05-01]. <http://www.cnki.net/kcms/detail/11.2625.V.20170203.1533.002.html>

(编辑 苗秀芝)