

基于线性内插神经网络的雷达目标一维距离像识别¹

孙光民 刘国岁* 王蕴红*

(北京工业大学电子工程系 北京 100022)

*(南京理工大学电子工程系 南京 210094)

摘要 本文提出一种新颖的神经网络模型——线性内插神经网络 (Linear Interpolation Neural Network, LINN) 用于雷达目标一维距离像识别。它可避开提取不变特征的难点, 利用目标一维距离像特征随姿态变化的信息来提高目标识别性能。实验结果表明, 采用 LINN 很好地解决了在大的姿态角范围内识别目标时所存在的计算量与识别率的矛盾, 提高了雷达对任意姿态目标的识别性能。

关键词 雷达目标识别, 神经网络, 一维距离像, 线性内插

中图分类号 TN957.5, TN-052

1 引言

对于雷达目标识别, 关键在于如何提取用于识别的不变特征, 已有不少雷达科技工作者致力于这项工作研究, 提出了许多方法^[1,2], 但结果并不尽人意。目前, 各种神经网络模型广泛应用于雷达目标识别^[3-5], 其中 BP 网络, RBF 网络以及 SOM 网络等在雷达目标识别中的应用受到人们重视, 但由于各自所存在的固有缺点, 使得由这几种网络组成的目标分类器性能不够理想, 特别对于姿态角变化范围较大的目标, 由于提取目标不变特征的问题一直没能很好地解决, 所以识别性能更是大打折扣。为了使目标在不同姿态时的特征相对平稳, 一般方法是将大姿态角变化范围分成若干小的子集, 并取各子集的平均特征或具有代表性的特征组成训练样本集。由于同一子集中各样本间具有一定差异, 而不同子集间的界限也往往是不分明的, 因此目标的分类具有一定的概率性, 即可能产生模糊。分类性能的好坏与分隔子集数的多少有关, 子集分隔太少, 识别率不高, 但子集太多, 计算量与存储量又急剧增加, 导致网络的规模过于庞大。

高分辨的一维距离像反映了目标精密的几何形状结构特征, 可以提供识别所需的特征信息, 但由于一维距离像是以散射点分布模型为依据的, 具有很强的视角依赖性。在不同的视角下, 同一目标可以具有完全不同的一维距离像, 而不同的目标在不同的视角下, 又可能具有近似相同的距离像, 因此, 这就给目标识别带来了一定的困难。可见仅依据一维距离像来进行目标识别, 信息是不完全的, 正确识别率也是相当低的。为了在大的姿态变化范围内准确识别目标, 就要想办法充分利用目标各种姿态的信息。本文提出了一种新颖的神经网络模型——线性内插神经网络 (LINN) 用来进行雷达目标识别。这种网络是利用目标一维距离像特征随姿态变化的信息来提高目标识别性能的。因为我们发现, 尽管目标一维距离像是随雷达视角变化的, 但由于目标姿态变化的连续性以及目标散射点分布的连续性, 其一维距离像变化是一个随视角变化而逐渐演变的过程。因此, 对于某种目标, 我们可以将其在某一姿态角下的一维距离像特征看作特征空间中的一个点, 而一维距离像随视角演变过程则在特征空间中形成一条特征轨迹线。本文所提出的 LINN 就是利用不同目标具有不同的特征轨迹线来进行目标识别的, 尽管在某些不同姿态下, 不同的目标可能具有近似相同的一维距离

¹ 1997-03-19 收到, 1998-05-23 定稿

像,但在姿态连续变化过程中,不同目标一维距离像的变化轨迹却不会完全相同。这表现在特征轨迹线上就是不同目标的特征轨迹线只有少数相交的点。

由于目标姿态是连续变化的,要准确无误地确定特征轨迹线是不可能的,也是不必要的。LINN 采用的是线性内插的方法来估计各类目标的特征轨迹线。首先在轨迹线上确定 M 个特征矢量点存于网络权值中,我们称之为顶点。相邻顶点之间姿态角变化间隔近似相等,相邻顶点之间所有其它的特征矢量点则由线性内插方法产生的分段线性的折线来近似。然后利用训练样本对网络进行训练,调整权值,从而调整顶点的位置,使网络对各类目标的特征轨迹线的估计达到最佳。

LINN 经过训练后可用于对未知目标的识别。对于未知姿态角目标一维距离像的识别准则是计算其特征点与各类目标特征轨迹线的最近距离(而非几个特殊点的距离),因此,网络的识别性能得到了改善。

2 线性内插神经网络及分类算法

2.1 网络结构

LINN 由输入层、隐层和输出层三层组成,网络结构如图 1 所示。其中,输入层为线性神经元,接收输入样本特征矢量,输入节点数为 N ,对应于特征矢量的维数。隐层神经元分为 K 组,每组 M 个神经元,其中 K 表示待识别目标的类别数, M 表示各类目标特征轨迹线上选定的顶点数;所有隐层神经元均与每一个输入神经元相连;隐层中各组的 M 个神经元按顺序排列,其连接权矢量分别表示各类目标的特征轨迹线上 M 个顶点的坐标,即目标在 M 个不同姿态角时的特征矢量;相邻顶点之间姿态角间隔近似相等,各相邻顶点连成的折线近似表示特征轨迹线;所以从第 1 个神经元到第 M 个神经元,形成了 $M-1$ 段折线,记忆了某类目标一维距离像特征随姿态角变化的轨迹线。输出层共有 K 个神经元,对应于 K 类目标;输出层中第 k 个神经元与隐层中对应的第 k 组的前 $M-1$ 个神经元相连,连接权均为 1。




图 1 LINN 结构图

2.2 分类算法

假定隐层阵列中第 k 组 M 个神经元与输入层神经元之间的连接权矩阵为

$$W^k = [W_1^k W_2^k \cdots W_M^k], \quad k = 1, 2, \cdots, K,$$

其中 $W_m^k = [W_{m1}^k W_{m2}^k \cdots W_{mN}^k]$, $m = 1, 2, \cdots, M$ 表示隐层中第 k 组的第 m 个神经元与输入层神经元之间的连接权矢量, 则 LINN 学习算法为:

(1) 对第 k 类目标, 在一定的姿态角变化范围内, 等间隔抽取 M 个一维距离像特征矢量, 作为特征轨迹线的初始顶点, 顺序赋给 $W_1^k, W_2^k, \cdots, W_M^k$ 作为初始权值, 其中 $k = 1, 2, \cdots, K$ 。

(2) 在训练样本集中任取属于 k' 类的特征矢量 $X = [x_1 x_2 \cdots x_N]^T$, 通过输入神经元分别输给各隐层神经元, 隐层中各组神经元由权值矩阵求得 X 与各相邻顶点连成的折线的垂直距离, 作为各折线起始顶点神经元的输出, 若垂直投影点落在折线两端点以外的延线上(即下式中常数 a 满足 $a > 1$ 或 $a < 0$), 则应取离 X 近的一端点与 X 之间的距离作为相应的输出, 即

$$y_m^k = \begin{cases} \|(X - W_m^k) - a(W_{m+1}^k - W_m^k)\|, & \text{投影点在折线段上}(0 \leq a \leq 1); \\ \min_{I=m, m+1} \|X - W_I^k\|, & \text{投影点超出两端点以外}(a < 0 \text{ 或 } a > 1); \\ k = 1, 2, \cdots, K, \quad m = 1, 2, \cdots, M - 1, \end{cases} \quad (1)$$

其中 $\|\cdot\|$ 表示取普通欧氏距离, 下同。标量常数 a 可根据投影定理确定为

$$a = \frac{(X - W_m^k)^T (W_{m+1}^k - W_m^k)}{W_{m+1}^k - W_m^k)^T (W_{m+1}^k - W_m^k)}. \quad (2)$$

图 2 给出了两维空间中隐层神经元计算距离的原理示意图。由图可见, 投影点 P_m 落在折线段上, $y_m = \|X - P_m\|$, 而 P_{m+1} 点却落在端点外的延线上, 所以 $y_{m+1} = \|X - W_{m+1}\|$ 。




图 2 隐层神经元在二维特征空间计算距离原理示意图

(3) 以上两步求得的隐层神经元的输出, 输送给对应的输出神经元。第 k 个输出神经元计算对应的隐层中第 k 组中 $M - 1$ 个隐层神经元输出中的最小值, 并记录输出最小值的隐层神经元的序号:

$$d_k = \min_{1 \leq m \leq M-1} y_m^k, \quad k = 1, 2, \dots, K; \quad (3)$$

$$h^k = \arg \min_m y_m^k. \quad (4)$$

(4) 比较所有 K 个输出神经元的输出, 并求出最小值:

$$d_c = \min_{1 \leq k \leq K} d_k. \quad (5)$$

若最小输出的神经元所对应的目标类 c 与 X 所属的目标类 k' 相一致, 则权值不调整, 转 (2)。

若最小输出的神经元所对应的目标类 c 与 X 所属的目标类 k' 不一致, 则按下列公式调整权值。

(a) 对应于最小输出神经元 c , 调整隐层中第 c 组与 X 最近的折线两个顶点 h^c 和 h^{c+1} 的权矢量:

$$W_{h^c}^c = W_{h^c}^c - \alpha(X - W_{h^c}^c), \quad (6)$$

$$W_{h^{c+1}}^c = W_{h^{c+1}}^c - \alpha(X - W_{h^{c+1}}^c), \quad (7)$$

(b) 对于 X 所属的目标类 k' , 调整隐层中第 k' 组离 X 最近的折线两个顶点 $h^{k'}$ 和 $h^{k'+1}$ 的权矢量:

$$W_{h^{k'}}^{k'} = W_{h^{k'}}^{k'} + \alpha(X - W_{h^{k'}}^{k'}), \quad (8)$$

$$W_{h^{k'+1}}^{k'} = W_{h^{k'+1}}^{k'} + \alpha(X - W_{h^{k'+1}}^{k'}), \quad (9)$$

转 (2)。

上述过程对所有训练样本进行学习, 并且训练样本可重复使用, 直到精度达到要求或重复次数达到预定要求为止。

权值调整公式中学习参数 α 初值设为 $\alpha_0 = 0.1$, 且随学习时间单调衰减:

$$\alpha = \alpha_0(1 - t/T), \quad (10)$$

其中 T 为预定重复次数。

训练完成后, LINN 便可用于对未知目标样本 $X = [x_1 x_2 \dots x_N]^T$ 进行识别。输入 X 后, 隐层神经元计算 X 与各折线段的距离, 并在相应的输出神经元中求得 X 与各类目标特征轨迹线的最近距离。对各输出神经元的输出进行比较, 具有最小输出的神经元所对应的目标类别便确定为 X 所属目标类别。

3 ISAR 目标回波数据及一维距离像特征提取

本文所采用的雷达目标回波数据为我国第一部实验 ISAR 系统在外场所采集的三种飞机实飞测试数据。三种飞机目标分别为安-26 螺旋桨飞机、桨状小型喷气式飞机和雅克-42 大型喷气式飞机。雷达系统采用窄带和宽带交替发射的工作方式, 窄带系统可提供目标跟踪信息, 而宽带信号则用于成像。接收机采用时频转换 (Stretch) 技术。首先产生一个与发射




图3 不同姿态下的目标一维距离像
(a) 雅克-42飞机的一维像 (b) 奖状飞机的一维像 (c) 安-26飞机的一维像

信号斜率相同的线性调频参考信号,参考信号与回波信号进行全去斜率混频。对点目标来说混频输出信号频率 f_m 与目标回波时延 T_R (或目标径向距离 R) 成正比,所以对于在径向上有多个散射点分布的目标回波,混频器输出频率各不相同,所以对其进行频谱分析,便可得到目标的一维距离像。

本文采用的回波数据就是这种经时频转换处理后的具有一定频率分布的信号,每个回波采样 256 点,因此,我们对这 256 点数据进行 FFT 便可得到一幅目标的一维距离像。对于各不同重复周期回波进行处理,便可得到一组随目标姿态变化的一维距离像。图 3 给出三种飞机在不同姿态时的一维距离像。

如果直接将 256 点的距离像作为特征送给分类器,则势必造成系统结构复杂,运算量急剧增加,而且由于过多的细节信息,导致网络的泛化能力下降,识别效果并不理想。所以,为了提取目标的有效特征,压缩特征矢量维数,本文对一维距离像进行预处理,具体步骤为:

(1) 首先设置一门限值,找出超过门限值的第一个距离单元 m_1 和最后一个距离单元 m_2 ,保留 m_1 与 m_2 之间与目标距离像有关的部分信息,而丢弃其余的无用信息;

(2) 将 m_1 与 m_2 之间的距离单元数作 n 等分,并将每一等份中各单元的反射强度作非相干平均,由于目标尺寸的差异,不同目标所对应的 $m_2 - m_1$ 值不同,但 n 可取相同的值,以保证特征矢量的维数相同,本文中选用 $n = 10$;

(3) 将反映目标径向尺寸信息的 $m_2 - m_1$ 值以及 n 个平均反射强度值组成 $n + 1$ 维的特征矢量用作目标识别。

由于飞机在飞行中高低角变化不大,对本文的识别方法影响不大,可认为高低角近似恒定,而目标的飞行距离变化可由雷达系统提供的窄带数据加以补偿,所以本文仅考虑目标在不同水平姿态角下的识别,考虑到飞机结构的对称性,水平姿态角变化范围取 $0-180^\circ$,其中水平姿态角定义为雷达视线与飞机轴线(从机头到机尾)之间的夹角。

经过对原始数据进行预处理,我们便获得了所需要的特征矢量集,特征矢量的维数为 11,特征矢量集分为三组,第一组用于特征轨迹线顶点初始化,第二组用于网络训练,第三组用于检验系统识别性能。

第一组特征矢量集由三种目标的各 60 幅一维距离像特征矢量组成,其中每一种目标的 60 个特征矢量均是在 $0-180^\circ$ 水平姿态角范围内均匀抽取的,相邻特征矢量之间姿态角变化间隔约 3° ,这组特征矢量作为特征轨迹线的初始顶点,赋给网络作初始权矢量。

第二组特征矢量集中包含三种目标的各 500 个特征矢量, 作为训练样本集, 对网络进行训练, 这组特征矢量是在 $0-180^\circ$ 姿态角范围内任意抽取的。

第三组特征矢量集包含三种目标的各 600 个特征矢量, 作为检验系统识别性能的样本集, 这组特征矢量也是在任意姿态角下随机抽取的目标一维距离像特征。

4 实验结果

本文中采用的特征矢量维数为 11, 所以线性内插神经网络的输入层神经元个数为 $N=11$; 目标类别数为 3 类, 所以网络输出神经元为 $K=3$ 个; 特征轨迹线顶点数选为 $M=60$; 所以网络隐层神经元分为 3 组, 每组 60 个神经元。

利用前面已获得的第一组特征矢量集对网络权值初始化, 并用第二组特征矢量集采用前面介绍的学习算法对网络进行训练, 调整特征轨迹线的顶点位置, 使网络对特征轨迹线的估计达到最佳。最后利用检验样本集对 LINN 雷达目标识别系统进行了性能测试, 实验获得了令人满意的结果。主要表现在, 网络训练速度很快, 对训练集所有样本重复使用 8—10 次便可使训练样本识别率达 99% 以上, 对测试集样本识别结果如表 1 所示, 在整个水平姿态角范围平均识别率达 94.61%。

表 1 LINN 目标识别结果

目标实际类别	网络判定的类别			正确识别率
	安-26	奖状	雅克-42	
安-26	569	2	29	94.83%
奖状	3	576	21	96%
雅克-42	34	8	558	93%
平均识别率				94.61%

5 结 论

本文提出了一种新颖的线性内插神经网络用于雷达目标识别, 由于 LINN 利用较少姿态角下的特征来估计整个 $0-180^\circ$ 姿态角变化范围内的特征信息, 充分利用了目标特征随姿态变化的连续性和顺序性信息, 从而很好地解决了在大的姿态角范围内识别目标时所存在的计算量(或网络规模)与识别率的矛盾, 提高了雷达对任意姿态目标的识别性能。实验结果表明: (1) 网络的结构相对来说比较简单, 隐层节点数可以任意选取, 在一定范围内对识别性能影响不大。(2) 网络训练速度很快, 这是因为权值初始化并不是随机的, 而是反映了特征轨迹线的内在规律性。网络一旦训练好, 则具有很好的泛化能力, 不会因加入新的训练样本而破坏网络原有性能。同时, 网络隐层是分类而设的, 所以也可以很容易地加入新的目标类别, 而不需要对所有权值加以调整。(3) 从识别性能来说, 对水平姿态角在 $0-180^\circ$ 范围内任意变化的目标, 具有很高的识别率。

由此可见, 线性内插神经网络在雷达目标识别领域具有良好的应用前景。

参 考 文 献

- [1] Stewart C, Lu Yichuan, Larson V. Vector quantization and learning vector quantization for radar target classification. SPIE 1993, Vol.1960, 115-124.
- [2] Lu Yichuan, Chang Kuochu. A Neural network approach for high resolution target classification. SPIE 1995, Vol.2484, 558-566.

- [3] Neiberg L, Casasent D P. Feature Space Trajectory (FST) classifier neural network. SPIE 1994, Vol.2353, 276-292.
- [4] Kouba E T, Rogers S K, Ruck D W, Bauer Jr. K W. Recurrent neural networks for radar target identification. SPIE 1993, Vol.1965, 256-265.
- [5] Jouny I, Garber F D, Ahalt S C. Classification of radar targets using synthetic neural networks. IEEE Trans. on AES, 1993, 29(2): 336-343.

1-D RANGE PROFILE IDENTIFICATION OF RADAR TARGETS BASED ON LINEAR INTERPOLATION NEURAL NETWORK

Sun Guangmin Liu Guosui* Wang Yunhong*

(Department of Electronic Engineering, Beijing Polytechnic University, Beijing 100022)

**(Dept. of Electron. Eng., Nanjing University of Science and Technology, Nanjing 210094)*

Abstract A novel neural network model—Linear Interpolation Neural Network(LINN) has been presented, which is used for radar target identification. And the 1-D range profiles of targets are used as identification feature. It is well known that the 1-D range profile reflects the precise geometric structure feature of a target, but it varies with the pose of target. The LINN utilizes just the variation information of the 1-D range profile with the pose to improve the identification performance of targets in any posture.

Key words Radar target identification, Neural network, 1-D range profile, Linear interpolation

孙光民: 男, 1960 年生, 博士, 副教授, 主要从事信号处理、雷达和通信系统设计、神经网络和自动目标识别以及逆合成孔径雷达成像等方面的研究工作.

刘国岁: 男, 1933 年生, 教授, 博士生导师, IEEE 高级会员, 主要从事噪声雷达、连续波雷达系统及信号处理技术研究.

王蕴红: 女, 1968 年生, 博士, 主要从事信号处理、神经网络及自动目标识别.