

基于极限学习机的目标智能威胁感知技术

王永坤^{1,2}, 郑世友^{1,2}, 邓晓波^{1,2}

(1. 中国航空工业集团公司雷华电子技术研究所, 江苏无锡 214063;

2. 航空电子系统射频综合仿真航空科技重点实验室, 江苏无锡 214063)

摘要: 空中目标威胁感知是智能空战的关键技术之一。针对空中目标威胁评估问题, 提出一种基于极限学习机的目标威胁智能感知策略。该方法首先提取目标威胁评估的高权重态势因子, 并采用隶属度函数进行归一化数值解译; 然后, 借助专家知识采用极限学习机理论对威胁感知的输入输出数据进行建模, 构建智能感知推理模型; 最后, 建立基于极限学习机的目标威胁智能感知流程。仿真结果表明, 该算法具有较高的威胁感知精度以及较好的算法实时性。

关键词: 空中目标; 威胁感知; 态势因子; 隶属度函数; 极限学习机

中图分类号: TN957; TP391.9 文献标志码: A 文章编号: 1672-2337(2020)04-0387-07

Intelligent Threat Perception of Aerial Target Based on Extreme Learning Machine

WANG Yongkun^{1,2}, ZHENG Shiyu^{1,2}, DENG Xiaobo^{1,2}

(1. AVIC Leihua Electronic Technology Research Institute, Wuxi 214063, China;

2. Aviation Key Laboratory of Science and Technology on AISSS, Wuxi 214063, China)

Abstract: Threat perception of aerial target is one of the key technologies in intelligent air combat. Strategy based extreme learning machine (ELM) is proposed to cope with the threat assessment problem. In the proposed method, the high weighting situation factors impacting on target threat are selected firstly, and then normalized and quantized via membership functions. The mapping relationship between the situation factors and target threat is modeled based on ELM. Finally, the threat perception process of target is established. The simulation results show the proposed algorithm can obtain high perception accuracy and realize online learning.

Key words: aerial target; threat perception; situational factor; membership function; extreme learning machine(ELM)

0 引言

当前空战决策仍依赖飞行员对各类传感器获取的多维态势信息进行融合分析, 并通过人为经验进行目标威胁估计, 进而完成作战决策。这种传统作战方式下的感知与决策, 一方面带有人为主观判断, 易引发战场不确定性; 另一方面, 不利于加速 OODA 环的迭代, 无法做到先敌发现、先敌攻击。此外, 下一代空战环境的典型特点是无人化、智能化、体系化^[1]。大型无人作战飞机将是未来空战的主角, 智能化的目标威胁感知^[2-3]作为大型无人作战飞机自主空战的关键支撑技术, 是实现智能化空战^[4-5]的基础。

针对未来智能化空战的典型关键技术需求, 目标威胁估计技术获得了国内外学者的广泛研究。目前国内外研究较多的目标威胁估计方法有多属性决策法^[6-7]、模糊逻辑法^[8-11]、贝叶斯网络法^[12-14]以及神经网络方法^[15-17]等。多属性决策法^[6]首先需要设定影响威胁评估的各态势因素固定权重值, 不同的权重值设置对威胁评估结果有很大影响, 算法鲁棒性较差。模糊逻辑法^[9]算法复杂性较高, 不适于工程应用。基于贝叶斯网络算法^[12]的威胁估计重点在于推理估计各态势因子对目标威胁度的影响概率, 当态势因子维度较高时, 各影响因子的概率推理复杂度将会呈指数级上升。神经网络方法^[15-16]本质上属于数据化方法, 通常借助专家知识数据进行训练建模, 实现对

目标威胁度的自主感知。但是,传统的 BP^[17-18]神经网络算法泛化能力有限,而且随着样本数增加,算法实时性将会大幅下降,无法做到在线学习。

极限学习机 (Extreme Learning Machine, ELM) 是由 Huang 等^[19-20]提出的一种新型神经网络算法,输入权值和偏置量是随机初始生成,输出权值随输入权值和偏差的变化得到。该算法相比经典的 BP 神经网络算法,首先具有学习速度快的优势,此外,BP 算法存在过度训练的问题,使其泛化能力变差,而 ELM 具有较好的模型泛化能力,而且算法的高实时性使其广泛应用于在线学习系统^[21-22]。本文基于 ELM 算法进行空中目标威胁智能感知问题研究,首先对影响目标威胁度的态势因子进行分析提取,并采用隶属度函数^[23]对各态势因子进行归一化数值解译;然后,采用极限学习机对威胁估计的输入输出样本数据进行训练建模,最后采用多组测试样本进行了与 BP 算法的对比仿真验证。

1 威胁感知态势因子提取

本文针对战斗机空空作战中的目标威胁感知问题进行研究,首先需要进行空中目标态势因子的提取。在空战中,目标的威胁属性是基于飞机上各传感器获取的信息进行综合判定,一般包括目标距离、速度、角度、机动性、目标类型、攻击能力、情报信息等十多种态势因子。但是在实际作战中,由于计算资源和实时性的限制,无法融合所有维度的态势信息进行威胁判定,因此,选择权重属性较高的态势因子进行目标威胁综合感知。

本文借助专家知识,从定性和定量两个方面选择高权重的态势信息。针对定量因子,目标的距离和速度是从机载雷达可获取的最直观信息,也是进行威胁判定的基础;此外,目标相对我方平台的进入角也是需要考虑的一个重要因素,不同的进入角决定着敌方对我方实施攻击的概率;再者,对目标探测的跟踪精度是对敌方目标作战意图预测的重要基础,而且较差的目标航迹质量大概意味着目标在作高机动运动,因此,目标的机动性也会影响对其探测的航迹质量。定性因子主要是目标类型,不同类型的目标具备不同的攻击能力,是决定目标威胁的一个关键属性。因此,空中

目标威胁感知的态势因子类型如图 1 所示,集合为 $Tr = \{Tr_1, Tr_2, Tr_3, Tr_4, Tr_5\} = \{\text{目标距离, 目标速度, 进入角, 航迹精度, 目标类型}\}$ 。

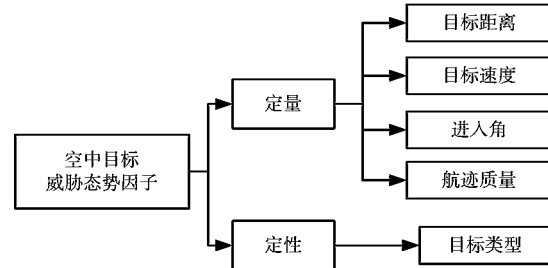


图 1 空中目标威胁态势因子类型

2 基于模糊隶属函数的态势因子解译

1) 目标距离隶属度函数

目标距离信息由机载雷达获取,距离越近,对我方平台威胁度越大,因此,其隶属度函数值应随距离增加而单调下降。具体函数选取为

$$Tr_1(x_1) = \begin{cases} 1, & 0 \leq x_1 \leq a_1 \\ 1 - \left[\frac{x_1 - a_1}{a_2 - a_1} \right]^2 \cdot 0.2, & a_1 < x_1 \leq a_2 \\ \left[\frac{a_3 - x_1}{a_3 - a_2} \right]^2 \cdot 0.8, & a_2 < x_1 \leq a_3 \\ 0, & x_1 > a_3 \end{cases} \quad (1)$$

式中, $a_1 = 0.3R$, $a_2 = R$, $a_3 = 1.15R$, R 是雷达探测距离, x_1 表示目标距离。

2) 目标速度隶属度函数

战斗机空战过程中主要面临亚音速飞机、超音速战机以及超音速空空导弹等目标威胁,而高超声速目标的攻击对象一般不会是作战飞机,因此,目标速度隶属度函数符合中间型分布函数形式,在低速和超高速区函数值较小。具体函数选取为

$$Tr_2(x_2) = \begin{cases} 0, & 0 \leq x_2 \leq a - a_2 \\ \frac{a_2 + x_2 - a}{a_2 - a_1}, & a - a_2 < x_2 \leq a - a_1 \\ 1, & a - a_1 < x_2 \leq a + a_1 \\ \frac{a_3 - x_2 + a}{a_3 - a_1}, & a + a_1 < x_2 \leq a + a_3 \\ 0, & x_2 > a + a_3 \end{cases} \quad (2)$$

式中, $a = 2 \text{ Ma}$, $a_1 = 0.5 \text{ Ma}$, $a_2 = 1.2 \text{ Ma}$, $a_3 = 2.5 \text{ Ma}$, x_2 表示目标速度。

3) 目标进入角隶属度函数

目标进入角以我平台与目标连线为基准,顺时针方向为正。当目标进入角在 $-90^\circ \sim 90^\circ$ 区间时,函数值为正,且当目标进入角越接近 0° ,函数值越大。具体函数选取为

$$Tr_3(x_3) = e^{-kx_3^2} \quad (3)$$

式中, $k=3.5$, x_3 表示目标进入角。

4) 目标航迹精度隶属度函数

目标航迹精度隶属度函数符合单调函数形式,对目标的跟踪精度越高,越有利于对目标意图的准确估计。因此,其函数值应随跟踪精度下降而单调上升。具体函数选取为

$$Tr_4(x_4) = \begin{cases} 0, & 0 \leq x_4 \leq a_1 \\ e^{-k(a_2 - x_4)^2}, & a_1 < x_4 \leq a_2 \\ 1, & x_4 > a_2 \end{cases} \quad (4)$$

式中, $k=2.75 \times 10^{-5}$, $a_1=30$, $a_2=300$, x_4 表示目标跟踪航迹质量。

5) 目标类型的隶属度函数

战斗机空战中面对的目标类型包括各类作战飞机以及敌机发射的空空导弹等,根据各类目标的攻击能力不同,给定隶属度函数如下:

$$Tr_5 = \begin{cases} 0.9, & \text{空空导弹} \\ 0.8, & \text{轰炸机机群} \\ 0.7, & \text{战斗机机群} \\ 0.6, & \text{轰炸机} \\ 0.5, & \text{战斗机} \\ 0.3, & \text{电子战飞机} \\ 0.2, & \text{预警机} \\ 0.1, & \text{其他飞机} \end{cases} \quad (5)$$

3 基于极限学习机的目标威胁智能感知

本节基于极限学习机(ELM)算法进行目标威胁智能感知技术研究,通过对威胁感知的输入输出样本数据进行学习建模,自主得到威胁感知结果,而不必进行繁琐的权重调节步骤。

3.1 ELM 算法原理

极限学习机是机器学习领域中的一种新型高效算法,以单隐层前馈神经网络架构为基础,通过高斯均匀随机分布生成的固定权值矩阵实现输入层到隐含层的连接,而隐含层与输出层的加权矩阵的学习是 ELM 算法建模的主要目标。因此,

ELM 算法只需设置训练网络的隐层节点个数,不需要调整网络的输入权值以及隐层神经元的偏置。基于上述描述可知,ELM 算法具备参数选择容易、学习速度快的优势。特别是在可用空战数据样本有限的条件下,能够以零误差逼近任意的线性和非线性函数。

极限学习机的具体算法原理如下:给定 N 个样本 $(\mathbf{u}_i, \mathbf{t}_i)$,其中 $\mathbf{u}_i = [u_{i1}, u_{i2}, \dots, u_{iN_u}]^T$ 和 $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{iN_y}]^T$ 分别为样本输入输出数据, N_x 个隐层神经节点, $N_x \leq N$,激活函数为 $h(u)$ 的单隐层前馈神经网络数学模型为

$$\sum_{i=1}^{N_x} \beta_i h(u_j) = \sum_{i=1}^{N_x} \beta_i h(\mathbf{a}_i \cdot \mathbf{u}_j + b_i) = y_j, \quad j=1, \dots, N \quad (6)$$

$\mathbf{a}_i = [a_{i1}, a_{i2}, \dots, a_{iN_u}]^T$ 是输入层与隐层的连接权值(随机生成), $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{iN_y}]^T$ 是隐层与输出层连接权向量, b_i 是偏移量(随机生成)。由文献[19]可知,采用激活函数 $h(u)$ 能够零误差逼近 N 个样本,则 $\sum_{i=1}^N \|y_i - t_i\| = 0$,即

$$\sum_{i=1}^{N_x} \beta_i h(\mathbf{a}_i \cdot \mathbf{u}_j + b_i) = t_j, \quad j=1, \dots, N \quad (7)$$

上述方程的矩阵形式为

$$\mathbf{H}\beta = \mathbf{T} \quad (8)$$

式中,

$$\mathbf{H} = \begin{bmatrix} h(\mathbf{a}_1 \times \mathbf{u}_1 + b_1) & \dots & h(\mathbf{a}_{N_x} \times \mathbf{u}_1 + b_{N_x}) \\ \vdots & \ddots & \vdots \\ h(\mathbf{a}_1 \times \mathbf{u}_N + b_1) & \dots & h(\mathbf{a}_{N_x} \times \mathbf{u}_N + b_{N_x}) \end{bmatrix}_{N \times N_x}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{N_x}^T \end{bmatrix}_{N_x \times N_y}, \quad \mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times N_y}$$

(9)

\mathbf{H} 为极限学习机的隐含层输出矩阵,其中第 i 代表第 i 个隐层神经元关于每个输入向量 u_1, u_2, \dots, u_N 的输出。

对于已经固定的随机输入权值 a_i 和隐层节点偏移量 b_i ,训练这个单隐层前馈神经网络实际上就是找到线性系统 $\mathbf{H}\beta = \mathbf{T}$ 的关于 $\hat{\beta}$ 的最小二乘解。

$$\|\mathbf{H}(\mathbf{a}_1, \dots, \mathbf{a}_{N_x}, b_1, \dots, b_{N_x})\hat{\beta} - \mathbf{T}\| = \min_{\hat{\beta}} \|\mathbf{H}(\mathbf{a}_1, \dots, \mathbf{a}_{N_x}, b_1, \dots, b_{N_x})\hat{\beta} - \mathbf{T}\| \quad (10)$$

等同于求最小化全局误差 E :

$$E = \sum_{j=1}^N \left(\sum_{i=1}^{N_x} \beta_i h(a_i \cdot u_j + b_i) - t_j \right)^2 \quad (11)$$

引理 1^[19]: 给定一个标准的具有 $n-L-m$ 结构的单隐层反馈神经网络, 和一组训练样本集 $\{x_j, t_j\}_{j=1}^N, x_j \in R^n, t_j \in R^m$, 激励函数 $g: R \rightarrow R$ 满足在任意区间上无限可微, 那么对于任意在 R^n 和 R 空间的任意区间内根据任意连续概率分布随机生成 ω_i 和 b_i , 都有隐层输出矩阵 H 可逆, 并且 $\|H\beta - T\| = 0$ 。

一般情况下, 隐层节点数远远小于训练样本数, 即 $N_x \ll N$, 因此需要求 H 的伪逆, 即

$$\hat{\beta} = H^\dagger T = (H^T H)^{-1} H^T T \quad (12)$$

式中, H^\dagger 为隐层输出矩阵 H 的广义摩尔逆^[24]。当 $H^T H$ 非奇异时, $H^\dagger = (H^T H)^{-1} H^T$, 当 $H H^T$ 非奇异时, $H^\dagger = H^T (H H^T)^{-1}$ 。根据岭回归原理^[25], 求得的 H^\dagger 为

$$H^\dagger = (H^T H + \lambda I)^{-1} H^T \quad (13)$$

3.2 基于 ELM 的目标威胁智能感知

本文采用极限学习机技术实现空中目标智能威胁感知, 首先选取输入输出数据, 其中输入数据为五维, 包括目标距离、目标速度、目标进入角、目标类型以及目标航迹精度, 输出为目标的威胁度, 并将样本数据以一定比例划分为训练样本和测试样本, 模型示意图如图 2 所示; 然后, 采用 ELM 算法对训练样本的输入输出数据进行训练建模; 训练完成后, 采用测试样本进行结果测试, 如果精度不满足, 重新训练。




图 2 空中目标威胁 ELM 模型

具体步骤如下:

步骤 1: 选取样本数据, 包括五维输入样本, 目标距离特征、目标类型、速度、目标进入角以及航迹精度, 输出样本数据即目标威胁度;

步骤 2: 将样本数据按一定比例划分为训练

样本和测试样本数据;

步骤 3: 选择 ELM 算法进行建模训练, 由于本文研究问题属于回归问题, 因此针对回归问题设置 ELM 算法参数, 即类型参数与隐层节点参数;

步骤 4: 采用训练样本数据进行建模训练;

步骤 5: 采用测试样本数据进行模型测试, 精度满足要求, 则进入下一步, 否则返回步骤 3 调整参数重新训练;

步骤 6: 结束。

4 算例分析与验证

4.1 样本数据选取

本节采用 ELM 算法对目标威胁估计进行特征建模, 从而实现目标威胁智能感知。从某目标威胁数据库选取目标威胁样本数据, 其中输入样本包括五维, 即目标距离特征、目标类型、速度、攻击角以及航迹质量, 样本选取策略如表 1 所示。

表 1 目标威胁度输入样本

态势因子	原始数值				
目标距离	0.4R	0.6R	0.8R	R	1.1R
目标类型	导弹	轰炸机 机群	战斗机 机群	轰炸机	战斗机 预警机
目标速度/ (m · s ⁻¹)	1.2V	1.1V	V	0.8V	0.6V
攻击角	0	±35°	±70°		
航迹质量/ m	300	200	100	80	30

其中距离因子中的 $R = 200$ km, 速度特征中的 V 表示声速。各特征值的归一化隶属度函数计算结果如表 2 所示。

表 2 输入样本的隶属度函数值

态势因子	归一化数值				
目标距离	0.99	0.96	0.89	0.80	0.40
目标类型	0.90	0.80	0.70	0.60	0.50 0.30
目标速度	0.70	0.60	0.30	0.20	0.10
攻击角	1	0.27	0.005 4		
航迹质量	0.99	0.72	0.30	0.23	0.12

通过上述数据预处理, 选取的样本数据共 2 250 组。按均匀分布随机抽取 2 000 组数据作为训练样本, 250 组数据作为测试样本。

为了更好地说明采用 ELM 算法进行目标威胁感知的合理性, 采用 ELM 和 BP 算法对比验证。

ELM采用随机的方式设置输入权值及隐层神经元的偏置,只需设置隐层神经元个数,设置为100;BP算法学习率设置为0.1,训练目标 1.0×10^{-5} ,隐层神经元个数同ELM算法。

4.2 仿真结果

首先选定2000组样本进行训练,250组样本进行测试。测试结果如图3和图4所示。从图4统计的预测误差百分比可知,ELM预测误差基本在0.1%的水平,BP的误差百分比约为0.5%,ELM大大低于BP算法的预测误差百分比。此外,统计得到250组样本中,ELM的预测均值误差为 5.0×10^{-4} ,BP的预测均值误差为 1.4×10^{-3} 。因此,基于ELM算法训练得到的感知模型具有较高的威胁估计精度。




图3 测试样本目标威胁估计结果(250组)




图4 目标威胁估计误差百分比(250组)

选定1750组样本数据进行模型训练,500组数据作为测试,测试结果如图5和图6所示。ELM和BP的威胁估计均值误差分别为 $5.2 \times$

10^{-4} 和 1.6×10^{-3} ,ELM的估计精度较BP算法有一个量级的提升。




图5 测试样本目标威胁估计结果(500组)




图6 目标威胁估计误差百分比(500组)

选定1250组样本数据进行模型训练,1000组数据作为测试,测试结果如图7和图8所示。ELM和BP的预测均值误差分别为 7.02×10^{-4} 和 1.87×10^{-3} 。

从以上三组仿真结果对比来看,不同数量的训练样本和测试样本下ELM算法均具有较高的威胁感知精度。为验证算法的学习速度和实时性,通过进一步的仿真,得到基于两种算法进行目标威胁感知的对比结果,如表3所示。可以看出在不同的训练样本数量下,ELM训练出的感知模型均具有较高的估计精度,相较于BP算法存在一个量级上的精度提升;而且更为重要的是,在同等训练样本数目下,ELM的训练时间要比BP算法低一到两个数量级,这对于实时性要求很高的威胁感知系统非常重要。

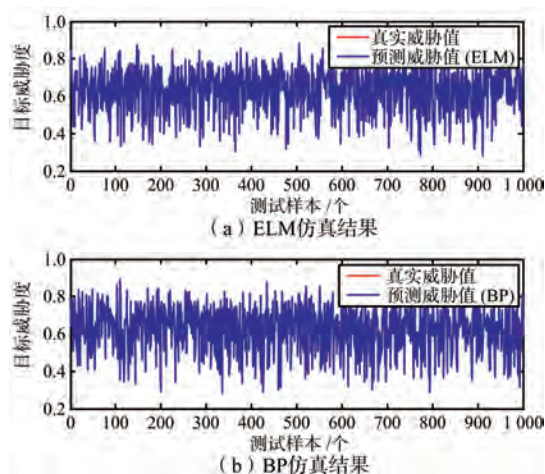


图 7 测试样本目标威胁估计(1000组)




图 8 目标威胁估计误差百分比(1000组)

表 3 BP 和 ELM 算法对比

训练 样本数	均值 误差 BP	时间 BP/s	均值误差 ELM	时间 ELM/s
2000	1.4×10^{-3}	1.241	5.0×10^{-4}	0.027
1750	1.6×10^{-3}	1.171	5.2×10^{-4}	0.022
1500	1.6×10^{-3}	1.169	5.5×10^{-4}	0.018
1250	1.87×10^{-3}	1.094	7.02×10^{-4}	0.014
1000	1.70×10^{-3}	1.082	5.73×10^{-4}	0.012

5 结束语

空中目标威胁感知是空战中作战决策的关键依据,涉及的态势因素众多且融合逻辑复杂。本文基于专家知识综合考虑空中目标的特点、类型以及威胁属性多重因素,并采用一种高性能机器学习算法—极限学习机进行目标威胁估计建模,从而实现空战环境下各类目标威胁度的实时智能感知。通过选取不同数量的测试样本数据,基于 ELM 算法和 BP 神经网络算法进行了威胁感知的对比仿真,结果均验证了 ELM 算法训练出的感知

模型具有较高的威胁估计精度和良好的实时性。

参考文献:

- [1] 黄长强. 未来空战过程智能化关键技术研究[J]. 航空兵器, 2019, 26(1):11-19.
- [2] BENAVALI A, RISTIC B, FARINA A, et al. An Application of Evidential Networks to Threat Assessment[J]. IEEE Trans on Aerospace and Electronic Systems, 2009, 45(2):620-639.
- [3] 杨远志, 于雷, 周中良, 等. 基于 RS-TOPSIS 的空中目标威胁评估[J]. 北京航空航天大学学报, 2018, 44(5):1001-1007.
- [4] 车继波. 人工智能在无人作战飞机上的应用与展望[J]. 电讯技术, 2018, 58(7):859-864.
- [5] 张蓬蓬. 空战体系演变及智能化发展[J]. 飞航导弹, 2019(3):60-64.
- [6] BISWAS P, PRAMANIK S, GIRI B C. TOPSIS Method for Multi-Attribute Group Decision-Making Under Single-Valued Neutrosophic Environment [J]. Neural Computing and Applications, 2016, 27(3):727-737.
- [7] 陈德江, 王君, 张浩为. 基于直觉模糊多属性决策的动态威胁评估模型[J]. 2019, 46(4):183-188.
- [8] CHEN Jun, GAO Xudong, ZHONG Linhui. Using Fuzzy Grey Cognitive Maps to Model Threat Assessment for UAVs [C]//IEEE 14th International Conference on Control and Automation (ICCA), Anchorage, AK, USA:IEEE, 2018:594-599.
- [9] AZIMIRAD E, HADDADNIA J. Target Threat Assessment Using Fuzzy Sets Theory [J]. International Journal of Advances in Intelligent Information, 2015, 1(2):57-74.
- [10] 王晓帆, 王宝树. 基于直觉模糊与计划识别的威胁评估方法[J]. 计算机科学, 2010, 37(5):175-177.
- [11] 张浩为, 谢军伟, 葛佳昂, 等. 改进 TOPSIS 的多态融合直觉模糊威胁评估[J]. 系统工程与电子技术, 2018, 40(10):2263-2269.
- [12] 刘跃峰, 陈哨东, 赵振宇, 等. 基于 FBNs 的有人机/UCAV 编队对地攻击威胁评估[J]. 系统工程与电子技术, 2012, 34(8):1635-1639.
- [13] OKELLO N, THORNS G. Threat Assessment Using Bayesian Networks[C]//Proc of 6th International Conference of Information Fusion, Cairns, Queensland, Australia: IEEE, 2003:1102-1109.
- [14] 杨健, 高文逸, 刘军. 一种基于贝叶斯网络的威胁评估方法[J]. 解放军理工大学学报(自然科学版),

- 2010, 11(1):43-48.
- [15] 韩城, 杨海燕, 涂从良. 空中对来袭目标威胁评估仿真研究[J]. 计算机仿真, 2017, 34(8):54-58.
- [16] 陈侠, 乔艳芝. 基于小波神经网络的无人机目标威胁评估[J]. 火力指挥与控制, 2018, 43(8):66-74.
- [17] DING Shifei, SU Chunyang, YU Junzhao. An Optimizing BP Neural Network Algorithm Based on Genetic Algorithm [J]. Artificial Intelligence Review, 2011, 36(2):153-162.
- [18] 王芳, 张军辉, 吴志泉. SVR 和 BP 在对空威胁评估中的应用[J]. 指挥控制与仿真, 2017, 39(2):51-55.
- [19] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme Learning Machine: Theory and Applications [J]. Neurocomputing, 2006, 70(1):489-501.
- [20] HUANG Guangbin, ZHOU Hongming, DING Xiaojian, et al. Extreme Learning Machine for Regression and Multiclass Classification [J]. IEEE Trans on Systems, Man, and Cybernetics, Part B: Cybernetics, 2012, 42(2):513-529.
- [21] MICHE Y, SORJAMAA A, BAS P, et al. OP-ELM: Optimally Pruned Extreme Learning Machine [J]. IEEE Trans on Neural Networks, 2010, 21(1):158-162.
- [22] KAHANDAWA G, CHOUDHURY T, IBRAHIM Y. Tire Size Identification Using Extreme Learning Machine Algorithm [C]//IEEE 27th International Symposium on Industrial Electronics, [S.l.]:[s.n.], 2018:571-576.
- *****
- (上接第 386 页)
- [7] SHAO Huaizong, DAI Jun, XIONG Jie, et al. Dot-Shaped Range-Angle Beam pattern Synthesis for Frequency Diverse Array [J]. IEEE Antennas and Wireless Propagation Letters, 2016, 15:1703-1706.
- [8] GAO Kuandong, WANG Wenqin, CHEN Hui, et al. Transmit Beam space Design for Multi-Carrier Frequency Diverse Array Sensor [J]. IEEE Sensors Journal, 2016, 16(14):5709-5714.
- [9] 赵永波, 刘宏伟. MIMO 雷达技术综述[J]. 数据采集与处理, 2018, 33(3):389-399.
- [10] 谭清莉, 张艺乐, 张伟, 等. FDA-MIMO 雷达主瓣欺骗干扰对抗方法[J]. 雷达科学与技术, 2017, 15(6):671-676.
- [11] 陈浩, 李荣锋, 邵银波, 等. FDA 最优频率增量选取必要性分析[J]. 雷达科学与技术, 2018, 16(6):650-655.
- [12] 陈浩, 李荣锋, 周必雷, 等. 基于加权模值的 FDA 最优频率间隔选取方法[J]. 现代雷达, 2019, 41(1):30-35.
- [13] SAMMARTINO P F, BAKER C J, GRIFFITHS H D. Frequency Diverse MIMO Techniques for Radar [J]. IEEE Trans on Aerospace and Electronic Systems, 2013, 49(1):201-222.
- [23] WANG Junwei, LI Hanxiong, WU Huaining. A Membership-Function-Dependent Approach to Design Fuzzy Pointwise State Feedback Controller for Non-linear Parabolic Distributed Parameter Systems with Spatially Discrete Actuators [J]. IEEE Trans on Systems, Man, and Cybernetics: Systems, 2017, 47(7):1486-1499.
- [24] LI Yenhuan, YEH P C. An Interpretation of the Moore-Penrose Generalized Inverse of a Singular Fisher Information Matrix [J]. IEEE Trans on Signal Processing, 2012, 60(10):5532-5536.
- [25] LI Yantao, HU Hailong, ZHOU Gang, et al. Sensor-Based Continuous Authentication Using Cost-Effective Kernel Ridge Regression [J]. IEEE Access, 2018, 6:32554-32565.

作者简介:



王永坤 男, 1988 年生, 河南洛阳人, 博士, 高级工程师, 主要研究方向为协同探测、雷达资源管理、最优化控制。
E-mail: wangyongkun1029@126.com

郑世友 男, 1972 年生, 湖北松滋人, 博士, 研究员, 主要研究方向为雷达系统、雷达数据处理。

邓晓波 男, 1982 年生, 湖南邵阳人, 博士, 研究员, 主要研究方向为机载雷达系统、信号与信息处理。

作者简介:



陈浩 男, 1993 年生, 湖北南漳人, 硕士, 助教, 主要研究方向为雷达抗干扰技术、阵列信号处理。
E-mail: ch19930922@163.com

叶泽浩 男, 1991 年生, 浙江慈溪人, 硕士, 助教, 主要研究方向为预警装备实现技术。

吴华新 男, 1982 年生, 湖南常宁人, 博士, 讲师, 主要研究方向为信息与信号处理、组网情报融合。

谢锐 男, 1979 年生, 安徽枞阳人, 硕士, 讲师, 主要研究方向为阵列信号处理、空间谱估计。

吴彩华 女, 1980 年生, 河北衡水人, 博士, 讲师, 主要研究方向为指挥信息系统。