

# 基于多通道卷积神经网络的磁性舰船目标运动参数估计\*

马剑飞, 颜冰, 林春生, 陈浩

(海军工程大学兵器工程学院, 湖北武汉 430033)

**摘要:**传统磁性目标运动估计效果依赖于目标的初始状态信息,为克服这一缺陷,建立磁性运动目标三分量投影模型,并据此生成磁性舰船运动目标在运动速度、航向、信噪比等参数变化情况下的10类目标的训练数据集、验证数据集以及测试数据集。设计多通道卷积神经网络,对目标的正横距离和运动速度进行估计,并比较和分析了不同的学习方式和激活函数对网络性能的影响。结果表明:Adam + tanh 组合方式的估计性能要优于其他组合方式,而且对磁性目标运动参数的估计效果比较精确,此方法相较于卡尔曼滤波、粒子滤波等估计算法的优越性在于运算复杂度低以及参数估计不需要目标初始状态信息。

**关键词:**磁性目标;投影模型;多通道卷积神经网络;参数估计

中图分类号:TJ-610 文献标志码:A 文章编号:1001-2486(2020)04-078-07

## Motion parameter estimation of magnetic ship target based on multi-channel convolutional neural network

MA Jianfei, YAN Bing, LIN Chunsheng, CHEN Hao

(College of Weaponry Engineering, Naval University of Engineering, Wuhan 430033, China)

**Abstract:** In order to overcome this defect of traditional magnetic target motion estimation's dependence on the initial state information of the target, a three-axis projection model of magnetic moving ship targets was established, and 10 kinds of target training datasets, validation data sets and test data sets of magnetic ship moving targets with variable parameters were generated. Multi-channel convolutional neural network was designed to estimate the distance abeam and velocity of the target, and the effects of different learning methods and activation functions on the performance of the network were compared and analyzed. The results show that the performance of Adam + tanh method is better than other methods, and the estimation effect of motion parameters is accurate. Compared with Kalman filter and particle filter, this estimation algorithm is calculated with preferable efficiency and independent of initialization for estimation.

**Keywords:** magnetic target; projection model; multi-channel convolutional neural network; parameter estimation

舰船磁场是水中兵器实施磁性探测的信号源,在水下布放测量节点可直接获取舰船目标磁场时间序列数据,据此可以对舰船目标运动参数进行估计。传统的滤波估计方式,如卡尔曼滤波以及粒子滤波,对目标的估计效果严重依赖于初始位置和磁矩等先验信息。而且传统的检测估计模型对于不同的目标或者同一目标的不同形态,需要设计者仔细思考如何去提取其特征,模型的最终识别效果也深受设计者们是否有充足的相关经验的影响。

卷积神经网络(Convolutional Neural Network, CNN)建立在认知机的基础之上<sup>[1-3]</sup>,通过卷积核的卷积处理来从输入图像中自学习得到目标特征。CNN具有良好的通用性,可以识别多种不同

的模式或目标,并对一定程度的扭曲形变具有良好的鲁棒性。目前CNN已经在图像检测、图像分割、语音识别等领域应用得十分广泛<sup>[4]</sup>,本文的研究工作主要集中在以多通道磁时间序列数据作为网络输入,利用CNN估计磁性舰船目标的运动参数。

### 1 建立磁性目标数据库

CNN的训练过程需要大量的磁场数据,所以在研究利用CNN估计磁性目标运动参数之前,先建立磁性运动目标产生的磁场三分量磁传感器的投影模型,并据此生成不同磁性目标在各种运动参数条件下的运动数据集。

\* 收稿日期:2019-01-03

基金项目:国家自然科学基金资助项目(51509252)

作者简介:马剑飞(1993—),男,陕西咸阳人,博士研究生,E-mail:438922417@qq.com;

颜冰(通信作者),女,教授,博士,博士生导师,E-mail:yanbing\_wh@yeah.net

## 1.1 椭球体与磁偶极子阵列混合模型

椭球体与磁偶极子阵列混合模型是舰船磁场建模中最常用的等效模型。在建立舰船磁场混合模型时,如图1所示,舰船可等效为一个均匀椭球体,并且在椭球体内沿长轴方向等间隔分布着一定数量的磁偶极子。其中均匀椭球体是用于拟合舰船的宏观磁场,它的长轴等于船长,短轴等于船宽,而磁偶极子阵列用于模拟舰船的局部不均匀磁场。




图1 混合模型

Fig. 1 Hybrid model

假设舰船磁场混合模型由  $N-1$  个磁偶极子和 1 个椭球体模型构成(统称为磁单元)。船长为  $L$ , 船宽为  $W$ , 磁偶极子个数为  $N-1$  时, 每个磁偶极子之间的距离为:

$$d = \frac{L}{N-1} \quad (1)$$

以舰船中心建立坐标系, 椭球体在舰船吃水面中心, 磁偶极子均匀分布在吃水面上, 第  $i$  个磁偶极子的坐标为  $(u_i, v_i, w_i)$  ( $i = 1, 2, \dots, N-1$ ), 则其在测量点  $P_j(x_j, y_j, z_j)$  所产生的磁场<sup>[5]</sup>为:

$$\begin{cases} H_{xj} = \sum_{i=1}^N (a_{xij}M_{xi} + a_{yij}M_{yi} + a_{zij}M_{zi}) \\ H_{yj} = \sum_{i=1}^N (b_{xij}M_{xi} + b_{yij}M_{yi} + b_{zij}M_{zi}) \\ H_{zj} = \sum_{i=1}^N (c_{xij}M_{xi} + c_{yij}M_{yi} + c_{zij}M_{zi}) \end{cases} \quad (2)$$

其中:  $j = 1, 2, \dots, m$  表示不同的测量点;  $M_{xi}, M_{yi}, M_{zi}$  ( $i = 1, 2, \dots, N-1$ ) 分别为第  $i$  个磁偶极子在  $x, y, z$  方向的磁矩;  $M_{xN}, M_{yN}, M_{zN}$  为均匀旋转椭球体的  $x, y, z$  方向磁矩;  $a_{xij}, a_{yij}, a_{zij}, b_{xij}, b_{yij}, b_{zij}, c_{xij}, c_{yij}, c_{zij}$  分别为磁偶极子对应的磁场计算系数。

$$a_{xij} = \frac{1}{4\pi} \left[ \frac{3}{r_{ij}^5} (x_j - u_i)^2 - \frac{1}{r_{ij}^3} \right]$$

$$a_{yij} = \frac{1}{4\pi} \left[ \frac{3}{r_{ij}^5} (x_j - u_i)(y_j - v_i) \right] = b_{xij}$$

$$a_{zij} = \frac{1}{4\pi} \left[ \frac{3}{r_{ij}^5} (x_j - u_i)(z_j - w_i) \right] = c_{xij}$$

$$b_{yij} = \frac{1}{4\pi} \left[ \frac{3}{r_{ij}^5} (y_j - v_i)^2 - \frac{1}{r_{ij}^3} \right]$$

$$b_{zij} = \frac{1}{4\pi} \left[ \frac{3}{r_{ij}^5} (y_j - v_i)(z_j - w_i) \right] = c_{yij}$$

$$c_{zij} = \frac{1}{4\pi} \left[ \frac{3}{r_{ij}^5} (z_j - w_i)^2 - \frac{1}{r_{ij}^3} \right]$$

其中,

$$r_{ij} = \sqrt{(x_j - v_i)^2 + (y_j - u_j)^2 + (z_j - w_i)^2}$$

当  $i = N$  时, 对应的均匀椭球体系数的计算公式为:

$$a_{xNj} = \frac{3}{4\pi} \left( \frac{A_j}{K^2 t_j} - \frac{1}{2K^3} \ln \frac{A_j + K}{A_j - K} \right)$$

$$a_{yNj} = \frac{3x_j y_j}{4\pi A_j B_j^2 t_j} = b_{xNj}$$

$$a_{zNj} = \frac{3x_j z_j}{4\pi A_j B_j^2 t_j} = c_{xNj}$$

$$b_{yNj} = \frac{3}{8\pi} \left( \frac{2A_j y_j^2}{B_j^4 t_j} - \frac{A_j}{B_j^2 K^2} + \frac{1}{2K^3} \ln \frac{A_j + K}{A_j - K} \right)$$

$$b_{zNj} = \frac{3A_j y_j z_j}{4\pi B_j^4 t_j} = c_{yNj}$$

$$c_{zNj} = \frac{3}{8\pi} \left( \frac{2A_j z_j^2}{B_j^4 t_j} - \frac{A_j}{B_j^2 K^2} + \frac{1}{2K^3} \ln \frac{A_j + K}{A_j - K} \right)$$

$$K = \sqrt{(L/2)^2 - (W/2)^2}$$

$$t_j = \sqrt{(x_j^2 + y_j^2 + z_j^2 + K^2)^2 - 4K^2 x_j^2}$$

$$A_j = \sqrt{\frac{1}{2}(x_j^2 + y_j^2 + z_j^2 + K^2 + t_j^2)}$$

$$B_j = \sqrt{A_j^2 - K^2}$$

## 1.2 磁性运动目标的磁场模型

CNN 的估计确实依赖于样本的完备性, 即它只能对与训练样本近似的目标做出较为准确的估计, 因此采用了大量具有不同磁矩特征、运动特征和信噪比的样本进行训练以保证样本的完备性。在磁矩特征完备性方面, 选用了随机生成的 10 类不同磁矩强度的目标, 每类目标由 10 个偶极子和单个椭球体构成模型, 从而保证了模型能够准确模拟舰船的局部磁矩特征和尺度磁矩特征。

图 2 为建立的磁性运动目标三分量投影模型, 可推出磁场信号的空间分布特征、时间和频率等信息<sup>[6]</sup>, 其中  $OXYZ$  坐标系是以三分量磁传感器为原点  $O$  建立的笛卡尔坐标系,  $X$  轴、 $Y$  轴和  $Z$  轴(垂直向下)的指向性与三分量磁传感器对应的指向性一致。  $oxyz$  坐标系是以舰船中心  $o$  为原点建立的笛卡尔坐标系,  $x$  轴与舰船目标的航行

方向一致,  $y$  轴垂直于舰船航向且指向右舷方向,  $z$  轴垂直向下。航行角  $\alpha_0$  为  $x$  轴与  $X$  轴的夹角,  $a$  点为圆心  $O$  点在  $x$  轴上的垂点, 即圆  $O$  的切点,  $R$  为圆  $O$  的半径, 磁传感器的布放深度为  $D$ 。




图 2 投影模型

Fig.2 Projection model

设舰船目标做匀速直线运动, 航行速度为  $V$ , 目标航行至切点  $a$  时对应零时刻点, 磁传感器的采样频率为  $f_s$ , 采样点数为  $N$  (零时刻点前后的采样点数都为  $N/2$ ), 则  $O$  点在  $oxyz$  坐标系中的运动方程为:

$$\begin{cases} x_j = x(k) = -Vk/f_s \\ y_j = y(k) = \pm R \\ z_j = D \end{cases} \quad (3)$$

其中:  $k = -N/2, -N/2 + 1, \dots, N/2$ ;  $\pm R$  分别对应同一航行角、同一圆周半径的上下切点。


将式(3)代入式(2)以及由坐标转换公式可得:

$$\begin{cases} H_{xj} = H_{yj} \cos\alpha_0 - H_{zj} \sin\alpha_0 \\ H_{yj} = H_{xj} \sin\alpha_0 + H_{zj} \sin\alpha_0 \\ H_{zj} = H_{zj} \\ B = \mu_0 H \end{cases} \quad (4)$$


其中:  $H_{xj}, H_{yj}, H_{zj}$  为三分量的磁场强度;  $\mu_0$  为真空磁导率;  $B$  为磁感应强度。

考虑实际舰船目标的运动速度、航向变化的特性以及信噪比的影响, 设置仿真参数为:  $V \sim U(5, 15)$ ;  $\alpha_0 \sim U(0, 2\pi)$ ;  $SNR \sim U(0, 10)$ ;  $R \sim U(-50, 50)$ ;  $M_{xi}, M_{yi}, M_{zi} \sim U(0, 1 \times 10^6)$ ;  $D = 20$  m;  $f_s = 20$  Hz;  $N = 2048$ ;  $cls = 10$ ;  $L = 120$  m;  $W = 10$  m。其中:  $V$  为目标的航行速度, 单位为 m/s;  $\alpha_0$  为目标的航行角;  $SNR$  为采集信号的信噪比, 单位为 dB;  $M_{xi}, M_{yi}$  和  $M_{zi}$  分别为磁性目标的第  $i$  个磁单元的  $x$  轴、 $y$  轴和  $z$  轴磁矩, 单位为  $A \cdot m^2$ ;  $cls$  为模型仿真种类数。考虑到实际环境中会存在噪声干扰, 对原始信号混入信噪比为  $SNR$  的高斯白噪声从而得到混合信号。


图 3 ~ 4 是不同仿真条件下投影模型生成的三分量磁场信号以及 1 Hz 低通 FIR 滤波后的仿真信号。图中,  $SNR = 5$  dB,  $\alpha_0 = \pi/4$ ,  $V = 10$  m/s,  $R = 20$  m。通过对比不难看出, 不同舰船目标在



(a) X 轴  
(a) X-axis



(b) Y 轴  
(b) Y-axis



(c) Z 轴  
(c) Z-axis

图 3 第三类目标三分量磁场信号

Fig.3 Three-axis magnetic field signal of category 3 goals




图4 不同条件下的目标磁场信号对比  
Fig.4 Comparison of magnetic signals under various conditions

同一航向、速度、正横距离条件下的三分量波形差异较大,而且存在纹波扰动,加之目标本身磁矩特性未知,因此很难人为地建立对不同目标的航向、

速度与正横距离进行估计的统计量。卡尔曼滤波、粒子滤波等算法的跟踪效果十分依赖于目标运动的初始状态以及目标的磁矩参数<sup>[7-8]</sup>,而在实际的应用背景中这些初始条件是未知的。深度学习方法较传统算法的优越性在于不需任何目标初始状态信息,只需通过 CNN 对磁性运动目标的特征数据与运动参数之间的关系进行足够的学习,就可以训练产生一个从目标特征数据到目标运动参数的映射关系。

基于磁性运动目标三分量投影模型和参数配置,仿真生成 3 种磁性目标特征数据集:

- 1) 生成 10 类目标的训练数据集  $M_{Si\_tr}$  (每类目标包含 200 组数据,记数据集的大小为  $10 \times 200$ );
- 2) 生成与训练目标的磁矩特征一致的验证数据集  $M_{Si\_va}$  (每类目标包含 100 组数据,记数据集的大小为  $10 \times 100$ );
- 3) 生成与训练目标磁矩特征不一致的 10 类目标测试数据集  $M_{Si\_ts}$  (每类目标包含 100 组数据,记数据集的大小为  $10 \times 100$ )。

每组仿真信号的大小都为  $4 \times 2048$  的矩阵,4 代表 X 分量、Y 分量、Z 分量和三轴合成量 C,2048 代表时间序列长度为 2048 点。估计的运动参数是磁性运动目标的正横距离和运动速度,所以训练标签分别设为式(5)中的仿真参数  $R$  与  $V$ 。考虑到水中兵器的应用背景,当舰船已经通过传感器时所估计的运动参数意义不大,应在舰船距传感器最近时(即正横方向)就完成运动参数估计,所以选取前 1024 个点进行运动参数估计。

## 2 网络结构设计

### 2.1 MC-CNN 设计

与图像分类检测的输入为二维的像素点不同,水下磁信号测量过程能够获取的只有 XYZ 三轴时域序列,此处将 XYZ 三轴信号序列以及信号的模 C 的序列组成一个  $4 \times 1024$  的矩阵作为网络的输入。图 5 是设计的多通道卷积神经网络 (Multi-Channel Convolutional Neural Network, MC-CNN) 的结构示意图。

目标运动速度和正横距离特征属于浅层特征,深度过高反而会会影响网络的泛化能力,所以设计的 MC-CNN 由 2 个卷积层、2 个池化层以及 2 个全连接层组成,其中卷积层 C1 和卷积层 C2 的卷积核的大小为  $[1, 11]$ ,卷积步长设为  $[1, 5]$ ,池化层 S1 和池化层 S2 采用 max-pooling 的池化方式,池化核的大小为  $[1, 7]$ ,池化步长设为  $[1, 3]$ 。卷积层 C1 的特征图数量为 32,大小为  $4 \times 342$ ;池




图 5 MC-CNN 结构

Fig. 5 Structure of MC-CNN

化层 S1 的特征图数量为 32,大小为  $4 \times 112$ ;卷积层 C2 的特征图数量为 64,大小为  $4 \times 38$ ;池化层 S2 的特征图数量为 64,大小为  $4 \times 11$ ;全连接层 F1 是池化层 S2 的排列展开;全连接层 F2 的点数为 1024,与全连接层 F1 采用全连接的方式连接;由于网络是对磁性运动目标的运动参数进行估计,所以输出层 OUTPUT 的大小为 1,其与全连接层 F2 之间以全连接的方式连接。

参数估计是一个典型的回归问题,所以设置误差准则为最小均方误差 (Minimum Mean-Square Error, MMSE) 准则,批处理 Batch 的大小设为 50。激活函数是 CNN 输入输出从线性关系到非线性关系的重要保证,目前流行的激活函数主要有 Sigmoid、tanh、ReLU 等方式。误差传递采取 Adam 算法,与传统的随机梯度下降算法 (Stochastic Gradient Descent, SGD) 保持单一学习率更新所有权重的方式不同,Adam 算法通过计算梯度的一阶矩估计和二阶矩估计为不同参数设定独立设计自适应学习率<sup>[9]</sup>,适应于解决包含高噪声的非稳态目标估计问题。

### 2.2 实验结果及分析

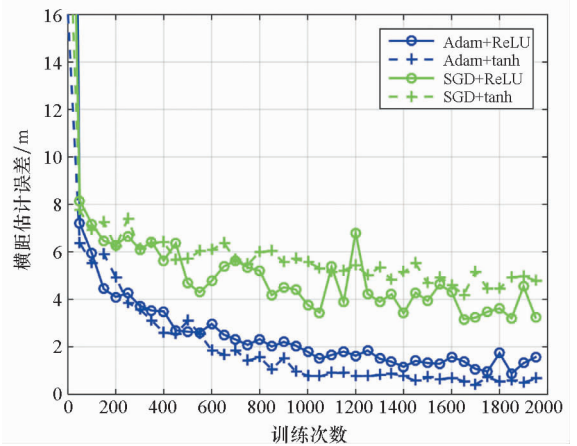
实验硬件平台为: Intel Core i5 - 5200 CPU @ 2.20 GHz, 8 GB RAM, NVIDIA GeForce 940 M; 实验软件平台为: Windows 7, TensorFlow-GPU 1.40。

在 1.2 节中,利用磁性运动目标磁场模型生成了 3 种磁性目标特征数据集,其中  $M\_Si\_tr$  集主要用于 MC-CNN 的训练, $M\_Si\_va$  集用于检验训练的网络对与训练目标的磁矩特征一致的目标的运动参数的估计能力, $M\_Si\_ts$  集用于检验训练的网络对与训练目标的磁矩特征不一致的目标的运动参数的估计能力。

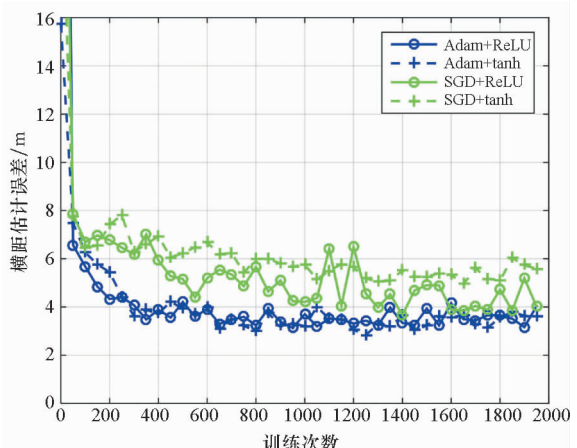
图 6(a) ~ (c) 分别是 4 种激活函数与学习方式的组合在  $M\_Si\_tr$  集、 $M\_Si\_va$  集和  $M\_Si\_ts$  集上正横距离的估计误差曲线。图 7(a) ~ (c) 分别是 4 种激活函数与学习方式的组合在  $M\_Si\_tr$

集、 $M\_Si\_va$  集和  $M\_Si\_ts$  集上目标运动速度的估计误差曲线。可以看出,Adam 学习方式在 3 种数据集上的估计效果和收敛速度都要优于 SGD 学习方式,这是因为 SGD 的估计效果依赖于网络训练的初始值以及其学习策略的调整方式容易陷入极小值点。


为了更加直观地比较不同激活函数与学习方式的优劣,迭代 1001 ~ 2000 次的正横距离与运动速度估计误差分别见表 1、表 2,表中加粗数值表示 4 类组合方式估计的最优结果。通过对比不同组合方式的估计效果,可以看出在 Adam 学习方式下,tanh 激活函数的效果要优于 ReLU 函数,



(a)  $M\_Si\_tr$



(b)  $M\_Si\_va$



(c) M\_Si\_ts

图6 正横距离估计误差曲线


Fig. 6 Estimated error curve of distance abeam

而在SGD的学习方式下,ReLU激活函数的效果略优于tanh函数。下面结合tanh函数和ReLU函数的数学公式予以解释。


$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

$$\text{ReLU}(x) = \max(0, x) \quad (6)$$


tanh函数是一种典型的饱和激活函数,反向



(a) M\_Si\_tr



(b) M\_Si\_va



(c) M\_Si\_ts

图7 速度估计误差曲线

Fig. 7 Estimated error curve of velocity

传播的更新需要逐层与激活函数的导数相乘,在输入很大或者很小时随着层数的增加会产生梯度消失问题<sup>[10]</sup>,而ReLU激活函数在 $x > 0$ 时的导数为1,这样就可以避免在输入较大的时候梯度消失的问题。从数据集的角度来考虑,输入信号波形都是在0值上下波动,而使用ReLU激活函数时会丢失数据负值特征,所以当以SGD方式进行误差反馈时,ReLU激活函数只是略优于tanh函数。与SGD方式不同,Adam方式通过计算梯度的一阶矩估计和二阶矩估计为不同参数设定独立设计自适应学习率,在接近收敛时梯度变得更加稀疏<sup>[9]</sup>,可以有效避免梯度消失和SGD学习方式的随机扰动问题,而tanh函数具有不丢失负值的优势,所以Adam+tanh组合方式的估计性能要优于其他的组合方式。在后文的参数估计过程中皆采用Adam+tanh的组合方式。

从表1和表2中可以看出,MC-CNN在M\_Si\_tr集、M\_Si\_va集和M\_Si\_ts集对正横距离的估计的最优结果分别为0.704 m、3.413 m和4.502 m,对运动速度估计的最优结果分别为0.256 m/s、0.727 m/s、0.826 m/s。这说明当网络在训练集训练完成后,仅利用目标磁场信息对非训练目标的正

表1 正横距离估计误差

Tab. 1 Estimated errors of distance abeam 单位:m

训练方式	M_Si_tr	M_Si_va	M_Si_ts
Adam + ReLU	1.465	3.519	4.793
Adam + tanh	<b>0.704</b>	<b>3.413</b>	<b>4.502</b>
SGD + ReLU	4.051	4.500	5.471
SGD + tanh	5.018	5.418	5.820

表 2 速度估计误差

Tab.2 Estimated errors of velocity  
单位:m/s

训练方式	M_Si_tr	M_Si_va	M_Si_ts
Adam + ReLU	0.353	0.742	0.890
Adam + tanh	<b>0.256</b>	<b>0.727</b>	<b>0.826</b>
SGD + ReLU	0.976	1.091	1.178
SGD + tanh	0.978	1.051	1.110

横距离估计的误差可控制在 5 m 以内,对目标运动速度估计的误差可控制 1 m/s 以内,其估计效果完全能够满足水下预置武器的指标要求。

为进一步说明算法的性能,利用海试数据对 MC-CNN 算法有效性进行测试。表 3 分别是对 A 型船、B 型船以及 C 型船的速度和正横距离的估计结果,其速度估计误差小于 1 m/s,正横距离估计误差小于 3 m。可以看出,磁性目标运动参数的估计效果完全能够满足水下预置武器的指标要求。

表 3 实测信号估计结果

Tab.3 Estimated results of measured signal

项目	速度估计/(m/s)			正横距离估计/m		
	估计	参考	误差	估计	参考	误差
A 型	4.87	5.20	0.33	-45.11	-48	2.79
B 型	6.51	6.15	0.39	12.54	11	1.54
C 型	3.87	3.22	0.65	19.73	22	2.27

### 3 结论

本文在椭球体与磁偶极子阵列混合模型的基础上,建立了磁性运动目标三分量投影模型,并据此生成了磁性舰船运动目标在运动速度、航向、信噪比等参数变化情况下的 10 类目标的训练数据集、验证数据集以及测试数据集。基于磁信号测量的特性提出了 MC-CNN,并比较和分析了不同的学习方式和激活函数对网络性能的影响。结果表明,Adam + tanh 的组合方式的估计性能要优于其他的组合方式,而且磁性目标运动参数的估计效果完全能够满足水下预置武器的指标要求。

MC-CNN 主要分为训练和测试过程,训练是一个对运算量要求很高的过程,一般都采用 GPU

加速,而测试过程是一个只涉及乘法和加法的前向运算过程。在实际的应用过程中,训练环节都是事先在计算机上训练完成,然后将训练好的参数植于单片机中。当系统检测到目标时,结合网络结构和网络参数就可以对目标特征进行估计,其相较于卡尔曼滤波、粒子滤波等估计算法的优越性在于运算复杂度低以及不需要目标初始状态信息,因此 MC-CNN 估计算法具有良好的工程应用性。

### 参考文献 (References)

- [1] Namatevs I. Deep convolutional neural networks: structure, feature extraction and training [J]. Information Technology and Management Science, 2017, 20(1): 40-47.
- [2] Ciregan D, Meier U, Schmidhuber J. Multi-column deep neural networks for image classification [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2012: 3642-3649.
- [3] 黄咨. 基于卷积神经网络的目标检测模型的研究 [D]. 上海: 上海交通大学, 2014.  
HUANG Zi. A target detection model based on convolutional neural network [D]. Shanghai: Shanghai Jiao Tong University, 2014. (in Chinese)
- [4] 王晓华. TensorFlow 深度学习与应用实践 [M]. 北京: 清华大学出版社, 2018: 183-237.  
WANG Xiaohua. TensorFlow deep learning and application practice [M]. Beijing: Tsinghua University Press, 2018: 183-237. (in Chinese)
- [5] 林春生, 龚沈光. 舰船物理场 [M]. 北京: 兵器工业出版社, 2007: 25-74.  
LIN Chunsheng, GONG Shengguang. Ship physics field [M]. Beijing: Weapons Industry Press, 2007: 25-74. (in Chinese)
- [6] 林春生. 水雷引信系统设计原理 [M]. 北京: 兵器工业出版社, 2013: 138-148.  
LIN Chunsheng. Design principle of mine detector system [M]. Beijing: Weapon Industry Press, 2013: 138-148. (in Chinese)
- [7] Birsan M. Non-linear Kalman filters for tracking a magnetic dipole [C]// Proceedings of International Conference on Maritime Electromagnetic, 2003.
- [8] Mcaulay A D. Computerized model demonstrating magnetic submarine localization [J]. IEEE Transactions on Aerospace and Electronic System, 1977, 13(3): 246-254.
- [9] Kingma D P, Jimmy B. Adam: a method for stochastic optimization [C]//Proceedings of the 3rd International Conference for Learning Representations, 2014.
- [10] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]// Proceedings of Conference on Neural Information Processing Systems, 2012: 1097-1105.