

船舶虚拟制造中狼群优化卷积神经网络的控制应用

肖世龙¹ 吴迪² 唐超尘^{3,4} 神显豪⁴ 张德育⁵

1 沈阳理工大学 沈阳 110159

2 哈尔滨工程大学计算机科学与技术学院 哈尔滨 150001

3 西安电子科技大学通信工程学院 西安 710071

4 桂林理工大学广西嵌入式技术与智能系统重点实验室 广西 桂林 541004

5 沈阳理工大学信息科学与工程学院 沈阳 110159

摘要 为了优化虚拟工业制造的控制策略,采用狼群优化的卷积神经网络算法进行虚拟工业制造控制研究。首先根据虚拟工业制造任务和资源数据,建立任务-资源列表,并结合单位矩阵对任务-资源列表进行稀疏化,形成虚拟制造单元;接着建立卷积神经网络虚拟制造控制模型,并采用狼群算法对权重和偏置进行优化;最后以所有任务的平均制造时间为目标函数,对虚拟制造单元进行训练优化。船舶主机虚拟制造实验证明,相比于常用的控制算法,通过合理设置卷积核池化尺寸的狼群优化卷积神经网络算法能够获得平均制造时间的最优解。

关键词: 虚拟工业制造;狼群算法;卷积神经网络;虚拟制造单元;平均制造时间

中图分类号 TP393

Control Application of Wolf Group Optimization Convolutional Neural Network in Ship Virtual Manufacturing

XIAO Shi-long¹, WU Di², TANG Chao-chen^{3,4}, SHEN Xian-hao⁴ and ZHANG De-yu⁵

1 Shenyang Ligong University, Shenyang 110159, China

2 College of Computer Science and Technology, Harbin Engineering University, Harbin 150001, China

3 School of Telecommunications Engineering, Xidian University, Xi'an 710071, China

4 Guangxi Key Laboratory of Embedded Technology and Intelligent System, Guilin University of Technology, Guilin, Guangxi 541004, China

5 School of Information Science and Engineering, Shenyang Ligong University, Shenyang 110159, China

Abstract In order to optimize the control strategy of virtual industrial manufacturing, the convolution neural network algorithm based on wolf swarm optimization is used to study the control of virtual industrial manufacturing. Firstly, according to the task and resource data of virtual industrial manufacturing, the task resource list is established, and the task resource list is sparse combined with the unit matrix to form the virtual manufacturing cell. Then, the convolution neural network virtual manufacturing control model is established, and the weight and offset are optimized by using wolf swarm algorithm. Finally, the average manufacturing time of all tasks is taken as the objective function and the manufacturing unit is trained and optimized. The virtual manufacturing experiment of marine main engine shows that compared with the common control algorithm, the convolution neural network algorithm optimized by wolves can obtain better average manufacturing time by setting the pool size of convolution kernel reasonably.

Keywords Virtual industrial manufacturing, Wolf swarm algorithm, Convolution neural network, Virtual manufacturing cell, Average manufacturing time

虚拟工业制造作为智能工业制造的一部分,在工业领域的制造中得到了广泛应用^[1],特别是在完成工业制造环节复

到稿日期:2020-09-25 返修日期:2021-03-10

基金项目:国家自然科学基金项目(61741303);辽宁省自然科学基金计划重点项目(20180520038);教育部产学研合作协同育人项目(201802284028);广西自然科学基金项目(2018GXNSFAA294061)

This work was supported by the National Natural Science Foundation of China(61741303), Key Project of the Natural Science Foundation of Liaoning Province(20180520038), Industry-University Cooperation Collaborative Education Project of the Ministry of Education(201802284028) and Guangxi Natural Science Foundation of China(2018GXNSFAA294061).

通信作者:肖世龙(108940643@qq.com)

杂^[2]、需求变化较多的工业制造任务时,虚拟工业制造的优势明显。利用虚拟制造,可以提前设定好工业制造流程,而且能够提前规避实际工业制造过程中可能遇到的问题;再者虚拟工业制造可以灵活应对制造需求变化而带来的加工环节顺序的调整。通过智能算法分析,可以有效优化虚拟制造控制策略,提高工业制造资源的使用效率。

当前关于虚拟制造的研究成果较多,大多数研究采用虚拟现实技术来辅助工业造型设计及改善模具成型工艺等,取得了良好的工业制造控制效果。文献[3]建立了立体视觉模型并采用了 Vega 虚拟现实开发平台,可以在产品制造前对结构设计及人机交互效果进行改进,最终有效缩短了产品的开发周期。文献[4]采用了虚拟现实技术完成了工业造型设计及模具成型工艺等,工业制造控制效果良好。

同真实的制造工艺一样,虚拟工业制造也存在任务工序控制问题,这是因为虚拟制造的对象是多种任务的集合,而制造的核心是多种资源在多种任务上的优化分配,因此要实现虚拟制造,首先需要构建虚拟制造分块单元,接着对分块单元进行优化调用,既要保证在有效时间段内完成虚拟制造任务,又要平衡同种资源的调用次数。虚拟工业制造的控制效果直接影响着产品制造的制造时间和生产成本。因此,本文将卷积神经网络模型用于虚拟工业制造控制。但是,卷积神经网络模型的可调参数需要大量的人工调试。狼群优化算法作为一种最近提出的群体智能优化典型算法,在参数寻优问题方面具有较大的应用潜力。为了有效缩短开发周期从而降低产品的生产成本,本文结合狼群算法对卷积神经网络进行优化,以进一步提高虚拟工业制造的控制性能。

1 虚拟工业制造

1.1 虚拟制造分块

虚拟制造分块指的是对虚拟制造任务和虚拟制造所用材料、设备及人力等资源按照可量化的一定数量进行分配^[5],进而组成虚拟制造单元。为了组成虚拟任务和资源对,将虚拟任务按类别划分,共划分为 N 类,然后将虚拟任务要使用的所有资源划分为 N 个类,从而构成 N 个虚拟制造单元。

在虚拟制造单元分块之前,需要对任务-资源关系进行数学表示,首先采用列表方式对任务资源关系进行整理,具体如图 1 所示。

| | R_1 | R_2 | R_3 | R_4 | R_5 | R_6 | R_7 |
|-------|-------|-------|-------|-------|-------|-------|-------|
| T_1 | 1 | 0 | 0 | 1 | 1 | 0 | 0 |
| T_2 | 0 | 0 | 1 | 0 | 1 | 0 | 0 |
| T_3 | 0 | 1 | 1 | 0 | 0 | 0 | 1 |
| T_4 | 0 | 0 | 0 | 1 | 1 | 0 | 0 |
| T_5 | 0 | 0 | 1 | 0 | 0 | 0 | 1 |
| T_6 | 1 | 0 | 0 | 1 | 1 | 0 | 0 |
| T_7 | 0 | 1 | 0 | 0 | 1 | 1 | 0 |

图 1 任务-资源列表

Fig. 1 Task resource list

为了实现任务-资源的数学计算,采用矩阵的方式来描述任务和资源的对应关系,然后结合单位矩阵的数学表示和稀疏矩阵的表示方法,对任务-资源矩阵进行重新整理,这样做一方面是为了提取有效的虚拟制造单元块,避免无效性的随机分配,因为随机分配可能造成某些虚拟制造块的任务和资

源具有弱相关性或者没有联系,从而使得虚拟制造分块失去意义;另一方面通过稀疏化,可以有效提高矩阵在数学计算中的效率。

虚拟制造单元的分块操作会将任务和资源进行配对,共同构成一组虚拟制造单元,为了避免配对的盲目性,可以通过列举法或者聚类算法来划分虚拟制造单元。将图 1 的列表按照上述思想操作后得到图 2。

| | R_1 | R_2 | R_3 | R_4 | R_5 | R_6 | R_7 |
|-------|-------|-------|-------|-------|-------|-------|-------|
| T_1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 |
| T_2 | 1 | 1 | 1 | 0 | 0 | 0 | 0 |
| T_3 | 0 | 1 | 1 | 0 | 0 | 0 | 0 |
| T_4 | 0 | 0 | 1 | 0 | 1 | 0 | 0 |
| T_5 | 0 | 0 | 0 | 1 | 1 | 0 | 1 |
| T_6 | 0 | 0 | 0 | 0 | 1 | 0 | 1 |
| T_7 | 0 | 0 | 1 | 1 | 0 | 1 | 0 |

图 2 变换后的任务-资源列表

Fig. 2 Task resource list after transformation

图 2 对任务-资源列表进行了稀疏划分,虚线内外分别构成了类似单位阵的分布,虚拟制造单元的划分尽量保证虚线内的“1”元素和虚线外的“0”元素更多,这样就可以根据“1”元素的分布来划分虚拟单元。若划分为 2 个虚拟制造单元,则可分为 $\{T_1, T_6, T_4, R_1, R_4, R_5\}$ 和 $\{T_2, T_3, T_5, T_7, R_2, R_3, R_6, R_7\}$;若要划分更多的虚拟制造单元,则可以对这 2 个虚拟制造单元继续拆分。结合资源占用时长、加工步骤的顺序及关联性要求,可以设置更多的限定条件来进行虚拟制造单元的划分。

1.2 虚拟制造资源控制

在构建完虚拟制造单元之后,结合这些虚拟制造单元中所有任务需要占用的资源时间、任务加工工艺流转时间以及加工工艺先后顺序等,完成虚拟制造资源控制^[6]。在控制过程中需要均衡分配同类资源,结合不同任务对资源的占用时间等,以完工时间和资源负荷等因素为主要量化标准对虚拟制造单元控制进行评价。

虚拟制造资源控制的评价指标较多,典型的有最大制造时间 C_{\max} ,其表述方法为^[7]:

$$C_{\max} = \max_{1 \leq i \leq n} \{C_i \mid i=1,2,3,\dots,n\} \quad (1)$$

其中, C_i 表示第 i 个任务完成的时间。在实际操作中,特别是采用深度学习算法完成虚拟制造单元调度时,常将所有任务的平均制造完成时间作为目标来进行训练优化。

$$\bar{C} = \frac{\sum_{i=1}^n C_i}{n} \quad (2)$$

本文选择 $\min(\bar{C})$ 为主要目标函数来研究虚拟制造单元的调度策略。

2 狼群优化的卷积神经网络

2.1 卷积神经网络

设样本集 $\mathbf{X} = (x_1, x_2, \dots, x_n)$, 输入的 n 个样本在卷积网络结构的第 l 层进行卷积和转换运算^[8]:

$$x'_j = f\left(\sum_{i \in n} x_i^{l-1} * w_{ji} + B^l\right) \quad (3)$$

其中, w_{ji} 和 B^l 分别表示第 l 层的神经元 i 与第 j 个输入对应的卷积核及偏置; $f(\cdot)$ 的表达式为:

$$f(z) = \frac{1}{1 + e^{-z}} \quad (4)$$

卷积核主要包含 n 个样本的 m 个特征卷积池化操作, 设卷积核尺寸为 $h \times w$, 池化方法有 2 种, 分别是^[9]:

$$g(x) = \frac{\sum_{k=1}^{h \times w} x_k}{h \times w} \quad (5)$$

$$g(x) = \max_{1 \leq k \leq h \times w} (x_k) \quad (6)$$

本文选择式(6)的池化方法, 令 $M = \frac{n}{h \times w}$, 样本 $\mathbf{X} = (x_1, x_2, \dots, x_n)$ 经卷积池化后的新样本为:

$$\mathbf{X} = (x_1, x_2, \dots, x_M) \quad (7)$$

然后将卷积池化后的样本按照式(3)进行转换运算。

设输出层的第 k 个节点的预测输出为 y_k , 实际输出为 d_k , 则误差项 δ_k 为^[10]:

$$\delta_k = (d_k - y_k) y_k (1 - y_k) \quad (8)$$

卷积神经网络经过训练后, 所有节点的误差函数为:

$$E = \frac{1}{2} \sum_{k=1}^M (d_k - y_k)^2 \quad (9)$$

可以按照式(8)和梯度递减方法不断地反向迭代, 求取最优权重和偏置, 以得到最优的训练结果, 而本文采用了狼群算法来求解权重和偏置。

2.2 狼群优化算法

在虚拟工业制造中, 虚拟制造单元的调度工作需要充分结合任务特点及加工工艺顺序, 并且对所有任务的资源控制时间进行综合调度, 再通过卷积神经网络对虚拟制造单元进行训练。本文使用卷积神经网络的权重参数和阈值参数来构建狼群, 并选择虚拟制造的平均制造完成时间 $1/\bar{C}$ 作为适应度函数。

设头狼为 $\mathbf{P} = [p_1, p_2, \dots, p_N]$, N 为权重和偏置总数, 狼群的总数量为 M , 其他 $N-1$ 只狼的坐标集合为 \mathbf{Q} , 其中某一只狼的坐标为 $\mathbf{Q}_i = [q_{i1}, q_{i2}, \dots, q_{iN}]$, $i = 1, 2, \dots, N-1$ 。

从 \mathbf{Q} 中选取部分样本作为方向狼, 并设方向狼数量为 T_{num} , 其移动方式如式(10)所示^[11]:

$$\begin{cases} Step_Y(k) = |\max_k - \min_k| / S \\ q_{i,k}^{\bar{z}} = q_{i,k} + \sin(2\pi \times g/h) \times Step_Y(k) \end{cases} \quad (10)$$

其中, S 和 h 分别表示权重值和移动方向。 $i = 1, 2, \dots, T_{\text{num}}$, $g = 1, 2, \dots, h$ 。

在方向狼的引导下, 其他狼的移动方式为^[12]:

$$\begin{cases} Step_B(k) = 2 \times |\max_k - \min_k| / S \\ q_{i,k}^{\bar{z}+1} = q_{i,k}^{\bar{z}} + Step_B(k) \cdot [d_k - q_{i,k}^{\bar{z}}] / |d_k - q_{i,k}^{\bar{z}}| \end{cases} \quad (11)$$

其中, $i = 1, 2, \dots, N - T_{\text{num}} - 1$ 。

$$D_k = \frac{1}{J \times \omega} \times \sum_{k=1}^J |\max_k - \min_k| \quad (12)$$

其中, ω 表示距离权重。在式(10)和式(11)的操作之后, 计算所有狼群的 \bar{C} , 若头狼的 \bar{C} 最小, 那么头狼位置不变, 否则将 \bar{C} 最小的狼更新为头狼。

最后非头狼对猎物围攻, 移动方式为^[13]:

$$\begin{cases} Step_W(k) = |\max_k - \min_k| / (2 \times S) \\ q_{i,k}^{\bar{z}+1} = q_{i,k}^{\bar{z}} + \lambda \cdot Step_W(k) \cdot |d_k - q_{i,k}^{\bar{z}}| \end{cases} \quad (13)$$

其中, $z = 1, 2, \dots, N-1$; λ 为 $[-1, 1]$ 内的随机数。

计算围攻过程中非头狼的 $1/\bar{C}$, 判断是否需要更新头狼, 然后根据 $1/\bar{C}$ 值对所有狼进行降序排序, 选择排序较前的狼更新狼群。最后将 $1/\bar{C}$ 值与头狼包含的权重和阈值进行比较, 若 $1/\bar{C}$ 达到了卷积神经网络的虚拟制造单元调度的阈值, 且 R 和 R_{max} 满足限制条件, 则运算停止。

2.3 虚拟工业制造的控制流程

狼群优化的过程就是获得 $\min(\bar{C})$ 的过程。具体来说, 就是不断求解适合虚拟工业制造的卷积神经网络的最优权重和偏置, 通过多次迭代, 不断更新头狼位置从而计算 $\min(\bar{C})$ 最优值^[14], 以获得稳定的卷积神经网络虚拟制造模型。基于狼群优化卷积神经网络的制造控制流程如图 3 所示。

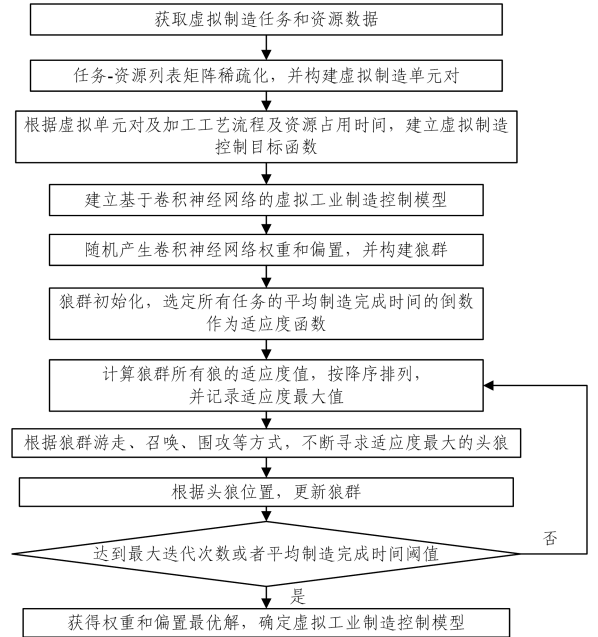


图 3 基于狼群优化卷积神经网络的制造控制流程

Fig. 3 Manufacturing control flow based on wolves optimization convolution neural network

3 实例仿真

为了验证狼群优化的卷积神经网络在虚拟工业制造控制中的性能, 对 7G80ME-C9.5 船舶主机进行虚拟制造控制仿真。首先对不同卷积核尺寸下各行业狼群优化的卷积神经网络的平均收敛时间进行测试; 其次对狼群算法的优化性能进行仿真, 验证卷积神经网络和狼群优化的卷积神经网络在船舶主机虚拟制造中的平均完工时间性能; 最后对常用的虚拟工业制造控制算法的平均完工时间性能进行仿真。提取 7G80ME-C9.5 样本之后, 结合单位阵进行稀疏化得到虚拟制造单元, 然后进行狼群优化的卷积神经网络的训练。

3.1 不同卷积核尺寸下的平均完工时间

卷积核尺寸决定了卷积运算对样本训练的作用, 实验选择 4 种不同的卷积核尺寸, 以验证在 4 种不同卷积核尺寸下的机械小车各个工艺的平均制造时间和训练时间。从表 1 可

以看出,随着卷积核尺寸的增加,机械小车的平均制造时间增加,标准差也随之增大,当尺寸为 2×2 和 3×3 时,两者的平均制造时间相差不大,但当尺寸为 5×5 时,相比于 2×2 时,其平均制造时间已经翻倍,这是因为最大池化方法选取的范围过大,所以训练性能差。

表1 不同卷积核尺寸下的平均制造时间

Table 1 Average manufacturing time of different convolution

| kernel sizes | | |
|--------------|------------|-----------------------|
| 卷积核尺寸 | 平均制造时间/min | 标准差 |
| 2×2 | 46.233 | 1.26×10^{-6} |
| 3×3 | 47.267 | 1.94×10^{-6} |
| 4×4 | 67.750 | 2.29×10^{-6} |
| 5×5 | 99.426 | 3.14×10^{-6} |

从图4中可以看出,卷积核尺寸越大,算法收敛速度越快,卷积核尺寸为 5×5 时收敛速度最快,卷积核尺寸为 2×2 时收敛速度最慢。这是因为 5×5 池化卷积时,参与训练的样本变少,所以训练时间短。在实际操作中,要综合考虑平均制造时间和收敛时间,对时间要求不高的情况下,可以考虑 2×2 卷积核。综合对比,本文采用 2×2 卷积模式。




图4 不同卷积核尺寸下本文算法的收敛时间

Fig. 4 Convergence time of proposed algorithm under different convolution kernels

3.2 狼群优化的效果验证

在虚拟制造单元的提取过程中,由于稀疏矩阵排列或者聚类阈值的不同,虚拟制造单元的数量有一定差异,本文差异化设置虚拟制造单元数量,并且分别采用卷积神经网络和狼群优化的卷积神经网络对样本进行训练,以验证狼群算法对卷积神经网络训练的优化性能。

从表2可以看出,随着虚拟制造单元数量的增加,平均制造时间获得了更优结果,这可能是对虚拟制造单元进行了更细粒度的划分,使参与卷积神经网络训练的样本增加,数据挖掘价值凸显。

表2 两种算法的虚拟制造控制性能

Table 2 Control performance of two algorithms in virtual manufacturing

| 算法 | 虚拟制造单元数量 | 平均制造时间/min | 训练时间/s |
|-------------|----------|------------|--------|
| 卷积神经网络 | 10 | 76.302 | 1.232 |
| | 30 | 70.246 | 6.012 |
| | 50 | 62.267 | 21.759 |
| | 70 | 62.264 | 27.408 |
| | 100 | 62.262 | 32.783 |
| 狼群优化的卷积神经网络 | 10 | 64.713 | 1.174 |
| | 30 | 53.442 | 6.135 |
| | 50 | 47.691 | 18.669 |
| | 70 | 47.686 | 24.433 |
| | 100 | 47.683 | 28.997 |

当虚拟制造单元达到50以后,平均制造时间并不随着虚拟制造单元数量的增加而明显减少,只有毫秒级别的差别;相反,随着虚拟制造单元数量的增加,训练时间增长明显,因此虚拟制造单元数量设置为50左右较好。通过对比两种算法发现,狼群算法优化的卷积神经网络,不论是在平均制造时间还是在训练时间方面,均表现出更优异的性能。

3.3 不同算法的虚拟制造性能

为了验证不同算法对虚拟制造控制性能的影响,实验分别采用常用的虚拟制造控制算法^[15]和本文算法对样本进行仿真,结果如图5所示。




图5 4种不同算法的虚拟制造控制性能

Fig. 5 Control performance of four different algorithms for virtual manufacturing

从图5中可以看出,在收敛时间方面,贝叶斯算法和遗传算法表现优异,但是其平均制造时间的收敛值分别为81 min和66 min;卷积神经网络和狼群优化的卷积神经网络虽然在收敛时间方面没有优势,但却获得了平均制造时间的最优解。综合对比,本文算法求解平均制造时间的性能最优,卷积神经网络算法次之,贝叶斯算法最差;而贝叶斯算法的收敛时间性能最优,卷积神经网络算法最差。

结束语 本文提出了一种基于狼群优化的卷积神经网络的虚拟制造控制方法。该方法可以缓解多任务时的制造资源占用问题,在资源负荷可控且能够完成所有任务的前提下,尽可能地减少平均制造时间,提高资源使用效率。通过对比发现,狼群优化的卷积神经网络具有较好的虚拟制造控制性能,适用性强。后续研究将进一步优化狼群算法参数,缩短狼群优化的卷积神经网络的收敛时间。

参考文献

- [1] YU J J, WU C M. Computational complexity analysis of virtual network mapping problem[J]. Computer Science, 2018, 45(11): 87-91.
- [2] LIU C, GUO D P. Application of virtual manufacturing technology in aircraft design and manufacturing[J]. Aviation Manufacturing Technology, 2017, 60(21): 34-38.
- [3] YAN B. Modeling design of industrial products based on virtual reality technology [J]. Modern Electronic Technology, 2019, 42(3): 184-186.
- [4] LIU D J, FAN Y S, CHEN H C, et al. Teaching and training platform for molding process and mold design based on virtual manufacturing technology[J]. Mold Industry, 2018, 448(6): 72-76.
- [5] WEI S N. Problem tracking and feedback platform based on vir-

- tual manufacturing technology[J]. *Mold Manufacturing*, 2019, 19(11):72-80.
- [6] LUO S S. Application of virtual manufacturing technology in automobile assembly process[J]. *Internal Combustion Engine and Accessories*, 2020(6):24-25.
- [7] CHEN D M. Research on dynamic scheduling method of production auxiliary tools based on virtual manufacturing[J]. *Machinery*, 2018, 45(2):6-9.
- [8] LIU Y P, SUN X J, ZHUANG X Y, et al. Research on bearing condition monitoring based on deep neural network[J]. *Manufacturing Technology and Machine Tool*, 2017(8):76-80.
- [9] LIU Y, YUAN X, GONG X, et al. Conditional Convolution Neural Network Enhanced Random Forest for Facial Expression Recognition[J]. *Pattern Recognition*, 2018, 84:251-261.
- [10] YANG H B, GONG W Y. Improvement of back propagation algorithm based on convolution neural network[J]. *Computer Engineering and Design*, 2019(13):126-130.
- [11] YANG Y, ZHANG H, XUE B. Wolf pack algorithm for multi-depot vehicle routing problem[J]. *Application Research of Computers*, 2017, 8(15):2590-2593.
- [12] LIU H, SUN R, LIU Q. The tactics of ship collision avoidance based on quantum-behaved wolf pack algorithm[J]. *Concurrency and Computation: Practice and Experience*, 2019(8):1-18.
- [13] ZHOU X Q, SONG W. Research on DBN network structure determination method based on wolf pack algorithm[J]. *Microelectronics and Computer*, 2018, 35(7):28-34.
- [14] WANG F Z. FCM Image Automatic Segmentation Based on wolf pack algorithm optimization[J]. *Control Engineering*, 2018(9):1727-1732.
- [15] LI C S, TANG M, LI S, et al. Service oriented hybrid cloud manufacturing model for ship supporting industry[J]. *Shipbuilding Engineering*, 2019(S1):118-121.



XIAO Shi-long, born in 1981, associate professor, master supervisor. His main research interests include virtual reality and virtual simulation.