DOI: 10.13382/j.jemi.B2306301

基于语义分割网络的 AGV 路径规划算法*

冉 宁[1,2] 张家明[1] 杨宏飞[1] 郝真鸣[1,3] 郝晋渊[4]

(1. 河北大学电子信息工程学院 保定 071002;2. 河北大学节能技术研发中心 保定 071002;
3. 河北大学物联网智能技术研究中心 保定 071002;4. 河北大学中央兰开夏传媒与创意学院 保定 071002)

摘 要:针对基于栅格地图的路径规划技术在面对大地图、高分辨率地图的情况下,存在的规划速度慢、内存占用高的问题,提出一种基于语义网络的网络搜索算法。首先使用语义分割网络对栅格地图进行预采样,其次通过图像学膨胀拓宽最优路径形成最优路径范围,增强算法鲁棒性,最后利用语义网络的特征图指导搜索算法规划,加快了高分辨率栅格地图的路径规划的速度。实验仿真表明,网络搜索算法较传统搜索算法,时间平均缩短 72.5%,遍历点数平均减少 51.6%,路径长度平均延长 0.73%,网络搜索算法可以有效加快路径搜索速度,减少内存占用。

关键词: 路径规划;语义分割;AGV;栅格地图

中图分类号: TP11;TN0 **文献标识码**: A **国家标准学科分类代码**: 510.80

AGV searching path planning algorithm based on semantic segmentation network

Ran Ning[1,2] Zhang Jiaming[1] Yang Hongfei[1] Hao Zhenming[1,3] Hao Jinyuan[4]

(1. College of Electronic Informational Engineering, Hebei University, Baoding 071002, China;
2. Laboratory of Energy-Saving Technology, Hebei University, Baoding 071002, China;
3. Laboratory of IoT Technology, Hebei University, Baoding 071002, China;
4. HBU-UCLAN School of Media, Communication and Creative Industries, Hebei University, Baoding 071002, China)

Abstract: A semantic network-based network search algorithm is proposed to address the problems of slow planning speed and high memory occupation of raster map-based path planning techniques in the face of large maps and high-resolution maps. Firstly, a semantic partitioning network is used to pre-sample the raster map, secondly, the optimal path range is formed by widening the optimal path through imagery expansion to improve the robustness of the algorithm, finally, the feature map of the semantic network is used to guide the planning of the search algorithm, which speeds up the path planning of the high-resolution raster map. Experimental simulations show that the network search algorithm reduces the time by an average of 72.5%, the number of traversal points by an average of 51.6%, and the path length by an average of 0.73% compared to the traditional search algorithm, and the network search algorithm can effectively speed up the path search and reduce the memory occupation.

Keywords: path planning; semantic segmentation; AGV; raster map

0 引 言

随着智慧城市的兴起,交通系统也逐渐更加智能化和自动化,自动引导车(automatic guided vehicle,AGV)由于其自动化程度强,灵活度高的优点被广泛应用于物流系统[1]。AGV 的调度与规划对降低物流成本、提高物流效率有着举足轻重的作用,而路径规划就是 AGV 规划技术中的核心部分[2]。

路径规划是为了在静态或者可移动的障碍物之

收稿日期: 2023-03-01 Received Date: 2023-03-01

*基金项目:国家自然科学基金(61903119)、河北省高等学校科学技术研究项目(BJ2021008)、教育部“春晖计划”合作科研项目(HZKY20220257)、河北省社会科学发展研究课题(20210301141)、河北大学科研创新团队项目(IT202306)资助

间,找到一条可无碰撞由起始状态到目标状态的路径[3]。在移动机器人领域,目前已经有许多成熟的算法可以解决这一问题。传统的算法有 A* 算法、RRT*(rapid-exploration random tree*)算法、蚁群算法、遗传算法等。A* 算法是一种搜索型算法,可以保证找到最优路径的算法(如果路径存在),但是寻优速度较慢,计算量大[4]。RRT* 是一种采样型算法,可以快速找到路径,但是 RRT* 算法的路径质量较差,需要花费时间靠不断迭代来优化路径。蚁群算法和遗传算法则是参考仿生学,依靠种群或个体间的学习与影响,达成优化路径的目的,鲁棒性强但是收敛速度慢,容易陷入局部最优[5]。

针对上述算法的局限性,国内外学者提出了许多相应的改进措施。文献[6]采用残差网络学习 A* 生成的路径指导分类器采样,改善 RRT* 算法的路径质量,加快收敛速度;文献[7]通过残差网络学习无人机在某个区域内的运动信息,如方向和速度,实现无人机的实时规划;文献[8]通过已经寻到的轨迹,限制抽样区域,加快算法收敛速度。文献[9]提出了将 A* 算法与模拟退火算法相结合来解决无人机避障的路径规划问题,能够利用较少内存,快速的得到一条综合代价较低且较为平滑的航迹;文献[10]提出将 D 算法与 A* 算法结合,加快 A* 算法收敛的速度,实现路径局部规划。但是上述改进的算法在应对大面积、高精度地图时,性能下降严重,路径精度与规划速度表现差强人意。

本文结合了搜索型算法与采样型算法的特点,针对大面积、高精度地图,提出了基于语义网络的网络搜索算法。通过语义分割模型和图像的形态学操作对地图进行采样,划定搜索算法的搜索范围,指导搜索算法进行,在保证精度的情况下减少遍历点数,加快搜索算法的规划速度,缩短找到最优路径的时间。

1 路径规划相关原理

1.1 路径规划问题描述

路径规划问题就是对于一张地图,找到起点到终点的无障碍最短路径。常见的地图建模方式有特征地图、拓扑地图、栅格地图以及直接表征法[11],本文中讨论的是基于栅格地图的路径规划问题。栅格地图是是指在空间和亮度上都已经离散化了的图像。把一幅栅格地图考虑为一个矩阵,矩阵中的任一元素对应于地图中的一个格子,矩阵中的值对应于栅格地图对应格子的类型,如矩阵中值为 1,栅格地图对应位置区域的类型为障碍。在本文中,对应关系如表 1 所示。

表 1 栅格地图类型与灰度值关系

Table 1 Relation between raster map type and gray value

栅格类型	可通行	障碍	起点	终点
对应值	0	1	2	3

起点和终点定义为 x_s 和 x_e,目标区域则为:

$$G(x_e)=\{x \in X \mid \| x-x_e \| < r\} \tag{1}$$

其中,$X \in \mathbb{R}^n$ 是路径规划问题的状态空间可通行路径,r 是目标区域的半径,目标区域即一个围绕终点的半径为 r 的圆形区域。对于一张存在可行路径的地图,用集合 $\sum$ 表示所有的可通行路径。

$$\sum:\sigma \in \sum \mid \sigma \in X_{free},\sigma[0]=x_s,\sigma[T]=x_e \tag{2}$$

式中:X_{free} 表示可通行状态集,σ 表示可通行路径,它的所有元素属于可通行状态集,并且第 1 个元素为起点 x_s,最后一个元素为 x_e。当路径不止一条时,需要有一个代价函数 $c(x)$ 来评判每条路径的优劣。通常情况下,代价函数由路径的长度来组成,如曼哈顿距离、对角线距离、欧几里得距离等[11],本文中的代价函数如下:

$$c(x_1,x_2)=D_1(w+h)-(D_2-2D_1)\min(w,h) \tag{3}$$

其中,w 表示两个状态的横向距离,h 表示两个状态的纵向距离,D_1 表示横纵移动的代价系数,D_2 表示沿对角线方向移动的代价系数。该代价函数表征了物体在栅格地图中以 8 个方向的条件下(可向相邻的 8 个栅格移动),两个状态间的对角线距离。因此对于路径 σ,代价函数的值越低,路径 σ 长度越短,通行效率越高。

由上式可得路径优化问题的数学描述如式(4)所示[6]。

$$\begin{aligned}&\sigma^*=\arg\min_{\sigma\in\Sigma} c(\sigma)\\&\text{s.t. } \sigma(0)=x_s\\&\sigma(T)\in G(x_e)\\&\sigma \in X_{free}(t)\end{aligned} \tag{4}$$

1.2 经典搜索算法

广度优先搜索算法(breadth-first search,BFS)与深度优先搜索算法(depth-first search,DFS)是搜索算法的基础思路[12]。BFS 算法从起始状态出发,优先遍历距离自己最近的状态,逐步向外拓展,直到找到达目的状态的最优路径。DFS 算法从起始状态出发,采用贪心策略的方式向目标状态遍历。在地图存在可行路径的情况下,DFS 算法可以最快的找到一条可行的路径,但是不能保证路径的最优性[13]。

A* 算法是一种静态路网中求解最短路径的最有效的启发式搜索方法,它综合考虑了 BFS 算法和 DFS 算法的代价,在保证最优的情况下,快速的找到最优路径。A* 算法的启发函数为:

$$f_A(n)=h(n)+g(n) \tag{5}$$

式中：$f_A(n)$ 是 A* 算法在状态 n 处计算得到的启发函数值，$h(n)$ 是由起始状态到状态 n 的距离，也叫状态 n 的代价，$g(n)$ 是由状态 n 到目标状态的距离，也叫状态 n 的启发值。由式(5)可以看出，A* 算法同时考虑了某一状态的代价与启发值，可以有目的性的快速遍历周围状态点。启发值 $h(n)$ 大于实际值会导致 A* 算法丧失最优性，启发值 $h(n)$ 小于实际值会导致 A* 算法遍历较多非最优路径状态，规划速度变慢[14]。在未知的地图中，启发值是无法准确计算的。实际应用时往往会采用诸如曼哈顿距离、欧几里得距离、对角线距离来估算某一状态的启发值，而上述估算的启发值都是在无障碍条件下的距离值，因此估算值一定不大于实际值，保证了 A* 算法的最优性，也减缓了规划速度。启发值不准确对规划速度带来的负面影响在高分辨率、障碍物密集的情况下尤为明显。D* 算法使用 Dijkstra 算法进行初始规划，并通过接受实时数据来减少启发函数不准确带来的影响，加快规划速度。本文提出的网络搜索算法，使用语义网络对地图进行预采样，减少算法遍历点，加快算法规划速度[10]。

2　网络搜索算法

本节介绍了语义网络的网络结构、损失函数以及搜索算法与网络模型融合方式。

2.1　网络结构模型

UNet 是医疗图像分割上应用非常普遍的神经网络模型，具有结构小巧、训练简单的特点，可以从小数据集中获得较好的效果[15]。考虑到路径规划是一种二分类问题，对于神经网络模型的参数量要求并不高，因此本节以 UNet 为基础，构建了路径语义分割网络模型。

模型采用编码器-解码器的结构，模型的结构如图 1 所示，左半部分对应编码器结构，右半部分对应解码器结构。为了减少实现过程的代码量，简化模型，在编码器结构和解码器结构中都用到了双层卷积(double Conv)模块，模块结构如图 2 所示，它包含两个分支，左分支经过两次卷积，右分支经过一次卷积，级联后输出。这是为了通过不同深度的卷积操作来获得不同层次的语义信息，增大模型的感受野[16]。在图 1 中，双层卷积块的括号内的数字由左到右分别表示模型的输入通道数和输出通道数，从图中可以看出，数据在其中经历了增加通道再减少通道的过程，这也对应着编码与解码的过程[17]。解码器过程还用到了上采样(UpConv)模块，该模块的结构为一层转置卷积层级联一层批正则化层(BatchNorm)。转置卷积是一种特殊的卷积操作，与普通的卷积层常常使数据尺度变小或者不变不同，转置卷积可以起到上采样的过程，将特征图扩大。转置卷积的应用让数据的解码过程不再过分依赖于全连接层，在解码过程可以保留空间信息和纹理信息，有效提高准确度[18]。最大值池化层(MaxPooling)则是由于图像中的相邻像素倾向于具有相似的值，因此通常卷积层相邻的输出像素也具有相似的值。这意味着，卷积层输出中包含的大部分信息都是冗余的，通过最大值池化层不断地从原始数据中提炼信息，最终得到占用空间较小，包含较多信息的数据表示，精简数据量的同时去除过多的干扰信息。

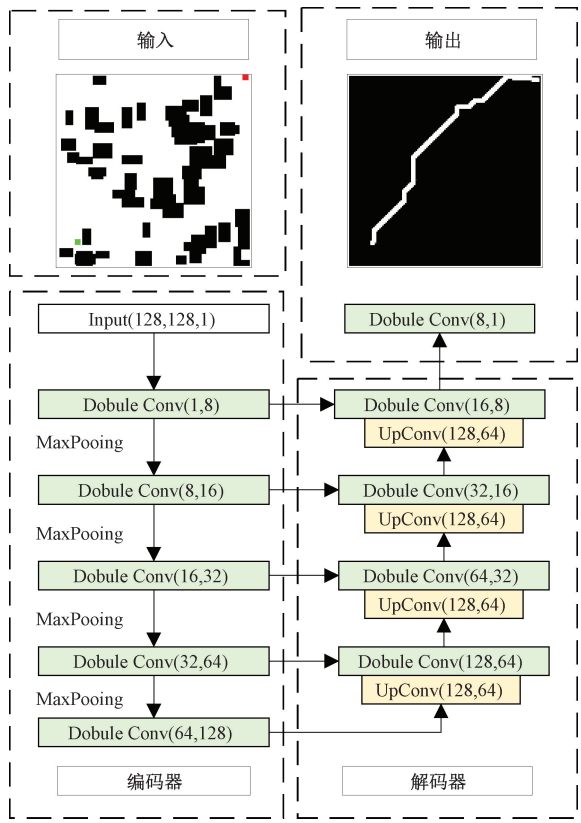

图 1　语义分割网络结构

Fig. 1　Semantic segmentation network structure diagram

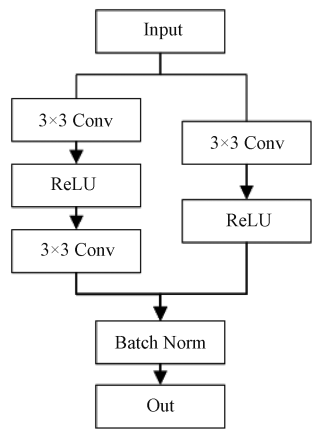

图 2　双层卷积块结构

Fig. 2　Double-layer conv block structure diagram

网络需要的输入长度、宽度、维度分别为(*W*,*H*,1)的张量,即一张灰度图所对应的张量。以(128,128,1)举例,它对应的是长宽皆为128的栅格地图。地图输入模型后,经过第1个双层卷积块后,结构变为(128,128,8),经过最大池化层后变为(64,64,8),接着进入第2个双层卷积块,依次向下进行编码器阶段。解码器阶段中,为图1中右侧部分,由下向上进行,分为4层,以第1层举例,其输入为编码器中第4层卷积块输出与第5层卷积块输出经过上采样模块后的桥接,即两个输出按通道的和。编码器中,第4层双层卷积块的输出为(16,16,64),第5层双层卷积块的输出为(8,8,128),经过上采样模块后,输出为(16,16,64),进行桥接后得到解码器的第1层输入为(16,16,128)依次向上进行,最后编码器的输出为(128,128,1),还原出地图原本的结构,解码器结构结束。解码器的输出传入输出模块中,此时的输入还需要经过Sigmoid函数进行二分类,得到模型的输出*O*。在输出*O*中,包含最优路径的区域的值为1,其他区域的值为0。由输出*O*的预测值,来指导搜索算法的进行,下文中,对模型简称为*Net*。

2.2　损失函数

本文的损失函数的数学表示由二值交叉熵损失(binary crossEntropy loss,BCELoss)和*Dice*系数损失组成,如式(6)所示。

$$L = \lambda_i \sum \alpha \mid BCEloss(O,T) \mid + \beta \mid dice(O,T) \mid \tag{6}$$

式中:*BCEloss*为二值交叉熵损失,*dice*是*Dice*系数损失,λ_i是平衡最优路径状态和非最优路径状态的参数,α,β是平衡交叉熵损失和*Dice*系数损失的参数,*O*是*Net*对输入地图的最优路径的预测值,*T*是输入地图的实际最优路径。在实际最优路径中,最优路径状态与非最优路径状态之间的数量比例不平衡,导致*Net*无法对最优路径状态进行有效的学习[15]。因此设置λ_i参数调整两种状态交叉熵在损失函数中的占比,降低非最优状态的影响,提高最优路径状态的影响。λ_i是平衡两种状态交叉熵占比的权重系数,如式(7)所示。

$$\lambda_i = \begin{cases} 0.9 & \sigma_i \in \text{path} \\ 0.1 & \text{其他} \end{cases} \tag{7}$$

式中:σ_i为*T*的某一个状态,path表示最优路径状态。通过λ的值来平衡最优路径状态与非最优路径状态在训练过程中对*Net*的影响。*BCEloss*的数学表示如式(8)所示。

$$BCEloss = -\sum_{c=1}^{2} \boldsymbol{y}_c \log(p_c) \tag{8}$$

式中:$\boldsymbol{y}_c$是*one - hot*向量,p_c表示预测状态属于最优路径状态的概率。*Dice*系数是一种集合相似度度量函数,用于计算两个样本的相似度。为了防止小样本时损失出现未定义现象,对分子分母同时加一,做柔和处理[6]。*Dice*损失的数学表达如式(9)所示。

$$dice(X,Y) = 1 - \frac{2 \mid X \cap Y \mid + 1}{\mid X \mid + \mid Y \mid + 1} \tag{9}$$

式中:*X*和*Y*分别表示*Net*对输入地图的最优路径的预测值和该地图最优路径状态的实际值。

2.3　图像形态学操作

图像学中的膨胀操作是一种图像处理技术,用于增加或扩大数字图像中的区域。它可以用来优化图像的形状和边缘,同时也可以用来填充空洞或去掉小的孔洞。膨胀操作的原理是将一个结构元素与图像的每个像素进行比较。如果结构元素全部包含在该像素的周围像素中,则该像素被认为是结构元素的一部分,并将其设置为膨胀后的像素值。通过不断重复这个过程,可以扩大图像中的所有区域,直到达到所需的大小。膨胀操作可以由式(10)表示:

$$A \oplus B = \{z \mid \exists b \in B, a + b = z, a \in A\} \tag{10}$$

其中,*A*表示原始图像,*B*表示结构元素,⊕表示膨胀操作,*z*表示输出图像中的像素点。在输入图像*A*中,对于每个像素*a*,如果它周围有一个结构元素*B*中的像素*b*,则输出图像中的像素*z*将被设置为1。换句话说,输出图像中的每个像素都会被扩展到其周围的结构元素范围内。

通过图像学的膨胀操作,可以扩展最优路径包含的范围,使网络训练更加容易,抗干扰与鲁棒性更强,图3的左和右分别是添加图像形态学膨胀后的标签与原始标签,可以看出经过膨胀操作后的标签区域更明显,更易被分割出来。

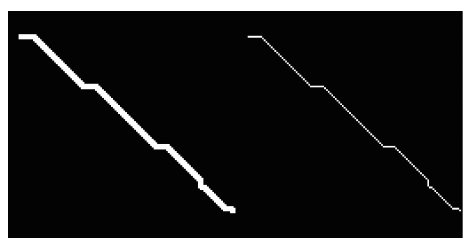

图3　标签图对比

Fig. 3　Label comparison

2.4　网络搜索算法

在搜索算法中,启发值的设置影响着算法进行的准确度与速度,但是由于路径的未知性,无法准确知道每个状态到目标状态的精确代价。实际使用时往往采用一种小于目标代价的近似代价去估算距离,却因此导致算法往往会搜索实际无用点,无法快速找到最优路径。在网络指导的搜索算法中,首先将需要寻路的地图送入*Net*中生成一张最优路径参数图,搜索算法只需要遍历最优

路径参数图中判断可能存在最优路径区域,减少无用点的遍历。若网络判定的最优路径区域中无法找到最优路径,则继续向外搜索,算法降级为普通搜索算法。网络指导的搜索算法详细描述如算法 1 所示。

算法 1:网络搜索算法

输入:栅格地图 M、起点 x_s、终点 x_e,网络 Net

输出:路径 path

```
初始化:开放表←起点,封闭表←Ø,f(x_s) = 0
初始化:预测图←Net(M),略过表←Ø
While 开放表不为空时
  当前点为开放表中代价最小点
  if 当前点是终点 then
  回溯父节点,返回路径,算法结束
  Else
  当前点移出开放表
  当前点加入封闭表
  寻找当前点的 8 个方向的邻点
   筛除已在封闭表的邻点
   筛出不在预测图中的邻点
   已在开放表中的,更新代价值
   不属于上述情况的,添加该邻点入开放表
return False
End
```

算法 1 首先进行初始化阶段,该阶段与 A* 算法类似,创建开放表、封闭表、并将起点 x_{init} 加入开放表中,网络搜索算法中还需要加载模型 Net ,将地图送入 Net 生成预测的最优路径图,最优路径图中,可能存在最优路径的区域值为 1,不可能存在最优路径的区域值为 0。在搜索进行时,路径图中被标记为 0 的区域到达终点的代价值将被设置为无穷。此时这些点在搜索算法中由于代价值无穷大将不会被选择,以此引导了算法寻路,初始化阶段结束,进入路径搜索阶段。搜索阶段的流程为算法 1 中 2~13 行,首先检测开放表是否为空,若不为空,则根据开放表内状态的启发值,找到启发值最小值对应的状态作为当前状态,记为 $x_{current}$,并将其取出开放表,放入封闭表。在本文中即当前状态的紧邻 8 个状态 x_{near},如图 4 所示。图中的深色部分为当前状态 $x_{current}$,周围浅色部分为邻近状态 x_{near}。对 $x_{current}$ 的 8 个邻近状态依次判断是否为障碍、是否在封闭表,是否在 Net 预测的最优路径图中。若某个邻近状态满足上述 3 个条件,且该状态未在开放表中,则将该状态放入开放表中,并设置其启发值、代价值、父辈状态,该代价值由式(11)计算。

$$h(n) = h_f(n) + h_{f-c}(n) \tag{11}$$

其中, $h_f(n)$ 表示父父辈状态的代价值, $h_{f-c}(n)$ 表示由父辈状态到当前状态的代价值。启发值则由式(5)计算。若某个邻近状态满足上述 3 个条件,且该状态已经在开放表中,则需要通过 $Update$ 函数更新当前状态的父辈状态、启发值、代价值,该函数如算法 2 所示。邻近状态中包含终点状态时,搜索到终点,找到当前地图最优路径,算法结束。当开放表为空时算法结束,该地图没有可行路径。

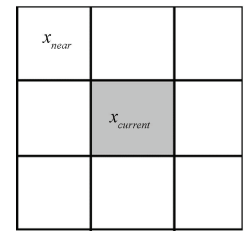

图 4　状态邻近区域示意图

Fig. 4　State adjacent area diagram

算法 2:Update

输入:某一状态点 x

输出:更新该状态点的父辈状态、启发值、代价值

```
找到状态点 x 的邻近状态集合 X_near
对所有状态集内的状态 x_near
 If 邻近状态代价值+邻近状态到该状态的代价值<当前代价值
  If 该邻近状态在封闭集
    将该邻近状态设置为父辈状态,重新设置代价与启发
遍历完成,函数结束
```

网络搜索算法与传统 A* 算法之间仅仅只是区别在于利用最优路径参数图划定了搜索范围,进行了一个非均匀抽样。因此网络搜索算法还可以与 D*、LPA* 算法等传统栅格搜索算法进行结合。在原理上网络搜索算法与 A* 的结合和与 D* 算法、LPA* 算法的结合类似,不再详细说明,在下一章的时候对比中,会展示网络模型 Net 与 A* 算法、D* 算法两种结合后的算法,并且比较与传统 A* 算法、D* 算法之间的差异。

3　实验与算法对比

本节中将进行网络搜索算法与传统算法的实验与对比。第 1 节介绍了网络搜索算法的部署细节,第 2、3 节介绍网络搜索算法与传统搜索算法之间的性能差异。

3.1　*Net* 训练过程

首先是训练集的准备工作。本文将路径规划问题的地图 M 设为(128,128)栅格大小。分别赋予每个栅格 0,1,2,3,4 五类值,代表 X_{free}、X_{obs}、σ、x_s、x_e 这 5 种状态或状态集。每个栅格对应灰度图的一个像素点,通过 OpenCV 保存为长宽皆为 128 的灰度图。为了保证得到合理且复杂的地图环境,地图生成采用了随机障碍个数、随机障碍大小、随机起始点、随机目标点,同时保证障碍占地图面积的 1/2 以上,起始点与目标点的距离为地图尺度的 80%以上。通过 Python 生成 12 000 张地图并保存用作训练集的数据。

训练集的标签通过 A* 算法生成。通过 A* 算法找出训练集中地图的最优路径,同时为了提升算法的鲁棒性,降低训练的难度,将最优路径进行膨胀处理。将膨胀集与 X_{free} 状态集的交集用作训练集的标签。标签的生成公式如式(12)所示。

$$label = dilate(T) \cap X_{free} \tag{12}$$

其中,$dilate$ 表示图像学的膨胀操作,在于扩充 Net 预测的最优路径状态集,提高算法鲁棒性。

训练选用 Adam 优化器,Adam 优化不需要过多的调整即可将网络模型优化至最优点邻域,但是会在最优点邻域震荡。因此学习率设置上选用 CosineAnnealingLR 动态学习率,表达式如式(13)所示。

$$\eta_t = \eta_{\min} + \frac{(\eta_{\max} - \eta_{\min})}{2}\left(1 + \cos\left(\frac{\pi T_{cur}}{T_{\max}}\right)\right) \tag{13}$$

其中,η_t 表示 t 时刻的学习率,$\eta_{\min}$ 表示最小学习率,$\eta_{\max}$ 表示最大学习率,$T_{\max}$ 表示周期,在训练中表示训练的周期数,这些参数全部由用户指定。T_{cur} 表示当前周期数。该动态学习率不仅会随着训练的进行,逐步调节学习率,让模型学到更精细的内容,帮助模型走出局部最优点[19]。设置学习率初始值为 0.01,$T_{\max}$ 为 100,训练 1 500 轮,得到最终模型 Net。

3.2　A* 算法与网络搜索算法的对比

本小节展示 A* 算法与 Net 结合后与传统 A* 算法之间的性能差异。为便于描述,与 A* 结合的网络搜素算法简称为 NA*。图 5 为本小节采用的实验地图,记为 M_1,空白部分为可通行路径,黑色矩形块为障碍区域,左下角圆形区域为起始状态,右上角三角区域为终止状态,以此地图为例子,展示算法之间的性能差异。

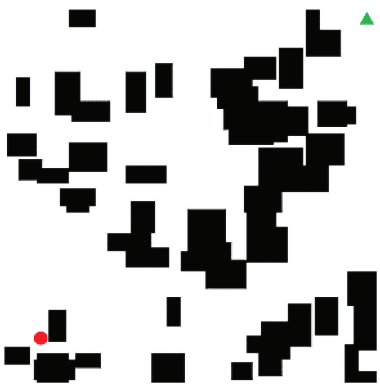

图 5　地图 M_1

Fig. 5　Map M_1

网络 Net 接收地图 M_1 输入后,生成的最优路径预测图如图 6 所示。最优路径参数图中,白色区域为最优路径存在的区域,最优路径是白色区域的子集。

传统 A* 算法与网络搜索算法的路径图分别如图 7(a)和(b)所示。

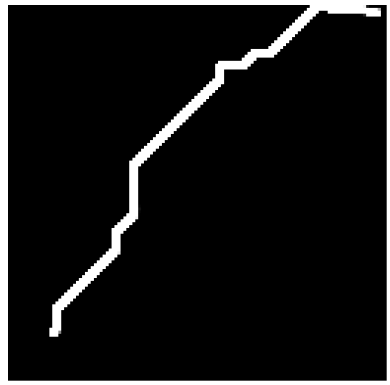

图 6　M_1 特征图

Fig. 6　M_1 feature map

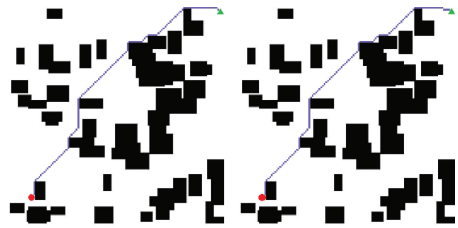

(a) A*路径图　(b) NA*路径图

(a) A* path　(b) NA* path

图 7　路径图对比

Fig. 7　Comparison of path maps

两者的路径差异较小,仅在路径的转弯处有前有后,两种算法的遍历点图如图 8 所示。

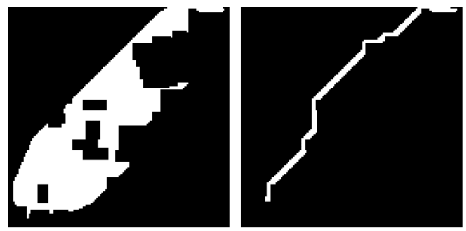

(a) A*遍历点图　(b)NA*遍历点图

(a) A* close map　(b) NA*close map

图 8　遍历点图对比

Fig. 8　Comparison of close maps

从图 8 的对比中可以明显的看出,A* 算法的遍历点明显较多。将遍历点图与路径图绘制在一起如图 9(a)和(b)所示。

网络搜索的遍历点围绕着最优路径,而传统 A* 则有过多的偏离最优路径的遍历搜索。为了更直观的观察差异,取规划时间、路径长度、遍历点数 3 种数据来查看两种算法之间的性能差异,对于地图 M_1,数据如表 2 所示。

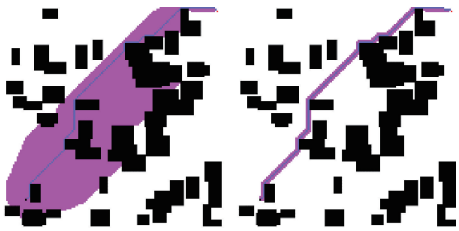

(a) A*融合图　(b) NA*融合图
(a) A* map　(b) NA* map

图 9　融合对比信息图

Fig. 9　Comparison of fusion information graph

表 2　路径数据表

Table 2　Path data table

算法	规划时间/s	路径长度/m	遍历点数
NA*	0. 244	178. 12	525
A*	5. 673	178. 12	4 151

为了避免偶然性,随机生成 100 张地图测试两种算法之间差异,表 3 是时间、遍历点数差异、路径长度差异 3 种指标比值的均值。

表 3　对比实验数据表

Table 3　Comparative experimental data table

指标	规划时间	路径长度	遍历点数
差异	缩短 72. 54%	延长 0. 74%	减少 51. 59%

3. 3　D* 算法与网络搜索算法的对比

本小节展示了 D* 算法与 *Net* 结合后与传统 D* 算法之间的性能差异。本小节所用的地图 M_2 如图 10 所示,空白部分为可通行路径,黑色矩形块为障碍区域,左上角圆形区域为起始状态,右下角三角区域为终止状态。

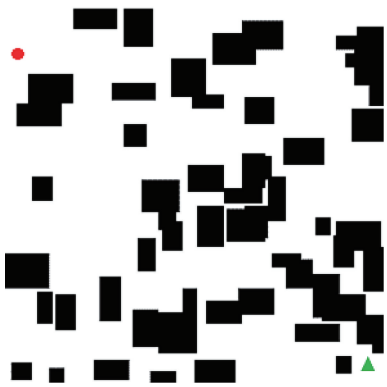

图 10　地图 M_2

Fig. 10　Map M_2

网络 *Net* 接收地图 M_2 输入后,生成的最优路径预测图如图 11 所示。最优路径参数图中,白色区域为最优路径存在的区域,最优路径是白色区域的子集。

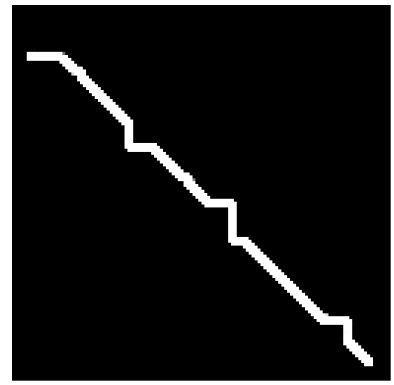

图 11　M_2 特征图

Fig. 11　M_2 feature map

两种算法的路径与遍历点的融合信息图如图 12 所示,可以直观的观察到遍历点与路径之间的关系以及两种算法在内存占用与遍历速度上的差异。

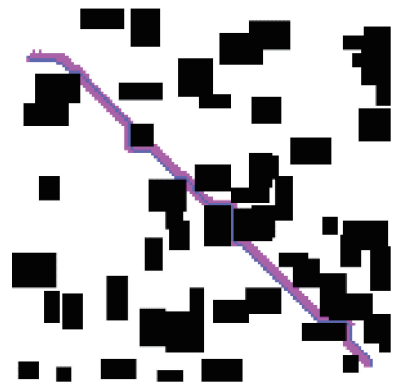

图 12　ND* 融合信息图

Fig. 12　Comparison of fusion information graph

网络搜索算法的遍历点始终围绕着最优路径。取规划时间、路径长度、遍历点数 3 种数据来直观的查看两种算法之间的性能差异,如表 4 所示。

表 4　路径数据表

Table 4　Path data table

算法	规划时间/s	路径长度/m	遍历点数
ND*	0. 077	174. 71	502
D*	0. 787	174. 71	10 754

从表 4 中可以看出语义网络对于 D* 搜索算法也有很强的改善效果,在速度上要明显优于 D* 算法。

3. 4　网络搜索算法与其他方法对比

本文提出的网络搜索算法可以与所有包含代价值和启发值的搜索类路径规划算法结合,上面两小节也证明

了网络搜索算法对搜索型路径规划算法具有一定的改进作用。本节将在规划时间与路径长度两个方面,对比网络搜索算法(本节采用 NA*)与目前的先进算法 ACO_PDG 算法[20](人工势场与蚁群的融合算法)、NRRT*[6]算法进行对比,他们在对比中分别代表近年来新兴算法中的抽样算法与仿生学智能算法。对比的地图选用第 3 节中的地图 M_2。NA* 算法、NRRT* 算法、ACO_PDG 算法的路径图分别如图 13、14、15 所示。

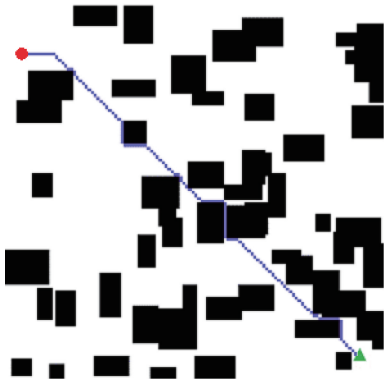

图 13　NA* 算法路径图

Fig. 13　NA* algorithm path

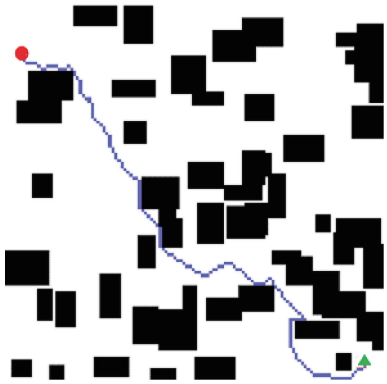

图 14　NRRT* 算法路径图

Fig. 14　NRRT* algorithm path

从路径途中可以明显看出,NA* 算法可以高效的找到最短路径,而 NRRT* 虽然也使用了残差神经网络 ResNET50 去提取地图信息,但是 NRRT* 算法在处理如图中的小缝隙、大地图时则存在较大困难,需要不断迭代去寻到最短路径。ACO_PDG 算法则与 NRRT* 算法的缺点类似,对于高分辨栅格地图需要较多次数遍历。

表 5 中,NRRT* 与 ACO_PDG 均为迭代了 3 次后的数据,由于这 3 种算法属于不同类别的算法,因此遍历点的对比没有意义,只对比规划时间与路径长度。由表中可以看出 NA* 算法在大型的高分辨率栅格地图的路径规划问题上具有明显优势。

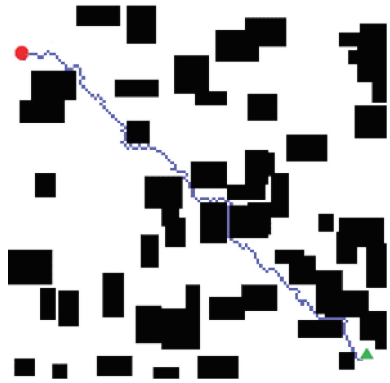

图 15　ACO_PDG 算法路径图

Fig. 15　ACO_PDG algorithm path

表 5　路径数据表

Table 5　Path data table

算法	规划时间/s	路径长度/m
NA*	0.157	174.70
NRRT*	3.787	205.36
ACO_PDG	5.677	196.81

4　结　论

针对传统搜索算法面对高分辨率地图时规划较慢,内存占用高的问题,本文提出了一种融合了语义分割网络的搜索算法,该算法结合了搜索算法与抽样算法的特点,通过语义分割网络构建一个非均匀采样器,减少搜索算法的遍历点数,从而在牺牲极小精度的情况下,大幅度提高规划速度,减少内存占用。通过设计对比实验,验证了算法的可行性与高效性,在平均长度延长 0.74% 的情况下,平均规划时间缩短了 72.54%,较传统算法有一定的提升。但是由于语义分割网络的训练集来源于传统 A* 算法,实际路径可能会存在不符合运动学规划的情况,需要加以改进。未来的工作将进一步提高模型的泛化能力,考虑使用实景地图进行语义分割预测与路径规划,并应用到 UAV 上。

参考文献

[1] 李永丹, 马天力, 陈超波, 等. 无人驾驶车辆路径规划算法综述[J]. 国外电子测量技术,2019, 38(6): 72-79.
LI Y D, MA T L, CHEN CH B, et al. A review of route planning algorithms for unmanned vehicles[J]. Foreign Electronic Measurement Technology, 2019, 38(6): 72-79.

[2] 杨立炜, 付丽霞, 王倩, 等. 多层优化蚁群算法的移动机器人路径规划研究[J]. 电子测量与仪器学报, 2021, 35(9): 10-18.

YANG L W, FU L X, WANG Q, et al. Path planning of mobile robot based on multi-layer optimization ant colony algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(9): 10-18.

[3] 张真诚. 机器人路径规划的改进粒子群-蚁群算法[J]. 电子测量技术, 2021, 44(8): 65-69.
ZHANG ZH CH. Improved particle swarm - ant colony algorithm for robot path planning [J]. Electronic Measurement Technique, 2021, 44(8): 65-69.

[4] 赵丽华, 万晓冬. 基于改进 A 算法的多无人机协同路径规划[J]. 电子测量技术, 2020, 43(7): 72-75, 166.
ZHAO L H, WAN X D. Multi-UAV collaborative path planning based on improved A algorithm[J]. Electronic Measurement Technology, 2020, 43(7): 72-75, 166.

[5] 江明, 王飞, 葛愿, 等. 基于改进蚁群算法的移动机器人路径规划研究[J]. 仪器仪表学报, 2019, 40(2): 113-121.
JIANG M, WANG F, GE Y, et al. Research on path planning of mobile robot based on improved ant colony algorithm[J]. Chinese Journal of Scientific Instrument, 2019, 40(2): 113-121.

[6] WANG J, CHI W, LI C, et al. Neural RRT*: Learning-based optimal path planning[J]. IEEE Transactions on Automation Science and Engineering, 2020, 17(4): 1748-1758.

[7] LIU Y, ZHENG Z, QIN F, et al. A residual convolutional neural network based approach for real-time path planning [J]. Knowledge-Based Systems, 2022, 242: 108400.

[8] GAMMELL J D, SRINIVASA S S, BARFOOT T D. Batch informed trees (BIT): Sampling-based optimal planning via the heuristically guided search of implicit random geometric graphs[C]. 2015 IEEE international conference on robotics and automation (ICRA), 2015: 3067-3074.

[9] 杨玉, 金敏, 鲁华祥. 融合简化稀疏 A* 算法与模拟退火算法的无人机航迹规划 计算机系统应用[J], 2019, 28(4): 25-31.
YANG Y, JIN M, LU H X. UAV flight path planning based on simplified sparse A* algorithm and simulated annealing algorithm[J]. Computer System Application, 2019, 28(4): 25-31.

[10] XIE K, QIANG J, YANG H J I A. Research and optimization of d-start lite algorithm in track planning [J]. IEEE Access, 2020, 8: 161920-161928.

[11] 肖金壮, 余雪乐, 周刚, 等. 一种面向室内 AGV 路径规划的改进蚁群算法[J]. 仪器仪表学报, 2022, 43(3): 277-285.
XIAO J ZH, YU X L, ZHOU G, et al. An improved ant colony algorithm for indoor AGV path planning [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 277-285.

[12] PATLE B K, GANESH B L, PANDEY A, et al. A review: On path planning strategies for navigation of mobile robot[J]. Defence Technology, 2019, 15(4): 582-606.

[13] 瞿新豪, 丁云飞, 谢亚琴. 基于栅格地图改进的智能路径选择算法[J]. 电子测量技术, 2022, 45(5): 86-93.
QU X H, DING Y F, XIE Y Q. Improved intelligent routing algorithm based on raster map [J]. Electronic Measurement Technology, 2022, 45(5): 86-93.

[14] JU C, LUO Q, YAN X. Path planning using an improved A-star algorithm[C]. 2020 11th International Conference on Prognostics and System Health Management (PHM-2020 Jinan), 2020.

[15] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015, 2015: 234-241.

[16] JIANG Y, YANG C, NA J, et al. A brief review of neural networks based learning and control and their applications for robots[J]. Complexity, 2017, 2017: 1-14.

[17] 谢晓蔚, 史健芳. 弱监督卷积神经网络的多目标图像检测研究[J]. 电子测量与仪器学报, 2019, 33(6): 31-37.
XIE X W, SHI J F. Multi-object image detection based on weakly supervised convolutional neural networks[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(6): 31-37.

[18] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.

[19] SUNG I, CHOI B, NIELSEN P. On the training of a neural network for online path planning with offline path planning algorithms [J]. International Journal of Information Management, 2021, 57: 102142.

[20] LIU J, YANG J, LIU H, et al. An improved ant colony algorithm for robot path planning[J]. Soft Computing, 2017, 21(19): 5829-5839.

作者简介

冉宁，2010年于河北大学获学士学位，2013年于华北电力大学获硕士学位，2017年于浙江大学获博士学位，现为河北大学电子信息工程学院副教授，主要研究方向为智能系统与控制、系统优化等。

E-mail：ranning87@hotmail.com

Ran Ning（Corresponding author）received the B. Sc. degree from Hebei University, and the M. Sc. degree from North China Electric Power University, and the Ph. D. degree from Zhejiang University. He is now a lecturer with the College of Electronic and Information Engineering, Hebei University. His main research interests include cyber-systems and control, system optimization.

郝真鸣，1987年获河北工业大学学士学位，2004年获河北大学硕士学位。河北大学正高级工程师，中国电子节能技术协会第六届理事会理事，河北工业大学校友总会第三、四届理事会理事，河北大学物联网智能技术研究中心主任，主要研究方向为自动化控制、检测技术等。

E-mail：hbdxhzm@163.com

Hao Zhenming received his B. Sc. degree from Hebei University of Technology in 1987 and his M. Sc. degree from Hebei University in 2004. He is now the senior engineer of Hebei University, member of the 6th Council of China Electronics Energy Conservation Technology Association, member of the 3rd Council of the Alumni Association of Hebei University of Technology, director of the Research Center for Intelligent Technology of the Internet of Things of Hebei University. His main research interests include automation control and detection technology.

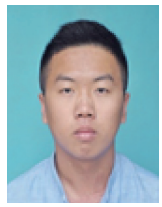

张家明，2021年于北京交通大学获得学士学位，现为河北大学硕士研究生，主要研究方向为AGV路径规划和智能算法。

E-mail：1485956457@qq.com

Zhang Jiaming received the B. Sc. degree from Beijing Jiaotong University in 2021. Now he is a M. Sc. candidate in Hebei University. His main research interests include AGV path planning and intelligent algorithms.

郝晋渊（通信作者），2013年于河北大学获学士学位，2015年于新南威尔士大学获硕士学位。现为河北大学讲师，主要研究方向为人工智能、信息技术、新媒体传播等。

E-mail：hjy@hbu.edu.cn

Hao Jinyuan received the B. Sc. degree from Hebei University, China, in 2013, and the M. Sc. degree from the University of New South Wales, Sydney, Australia, in 2015. She joined Hebei University in 2015. She is now a lecturer with the HBU-UCLan School of Media, Communication and Creative Industries, Hebei University. Her main research interests include artificial intelligence, information technology and new media communication.