本文已被 2023年遗传与进化计算大会录用。如需引用本文，请使用以下引文：MaryamKebari、Annie S.Wu 和 H. David Mathias（2023）。群体智能系统响应阈值模型中的 PID 启发式改进。载于遗传与进化计算大会论文集。

arXiv:2304.12385v1 [cs.MA] 24 Apr 2023

群体智能系统中响应阈值模型的受PID启发的修改

Maryam Kebari 中佛罗里达大学 奥兰多，佛罗里达州，美国 m.kebari@knights.ucf.edu

Annie S. Wu 中佛罗里达大学 奥兰多，佛罗里达州，美国 aswu@cs.ucf.edu

H. David Mathias 威斯康星大学拉克罗斯分校 拉克罗斯，威斯康星州，美国 dmathias@uwlax.edu

摘要

在本研究中，我们探讨了使用 PID（比例 - 积分 - 微分）控制回路因子来修改去中心化、非通信、基于阈值的群体中响应阈值的有效性。我们的群体中的每个智能体都有一组四个阈值，分别对应于该智能体能够执行的一项任务。当刺激高于相应阈值时，智能体将执行特定任务。修改阈值的能力使智能体能够根据任务需求动态地进行专门化。当前用于动态调整阈值的方法通常采用学习与遗忘过程来调整阈值。这些方法能够有效地完成一次专门化，但当任务需求发生变化时，可能难以重新专门化。受 PID 控制回路启发，我们的方法根据当前任务需求值、任务需求的变化以及先前任务需求的累积总和来改变阈值。我们表明，在任务需求不变、恒定以及发生突变的情况下，我们的受PID启发的方法具有可扩展性，并且优于固定响应阈值以及当前的学习与遗忘响应阈值。这种优越性能源于我们的方法能够根据不断变化的任务需求反复重新专门化。

关键词

多智能体系统，群体智能

ACM参考文献格式：

Maryam Kebari, Annie S. Wu, and H. David Mathias。2023年。群体智能系统中响应阈值模型的受PID启发的修改。载于遗传与进化计算会议（*GECCO '23*），*2023*年*7*月*15*日至*19*日，葡萄牙里斯本。ACM，纽约州纽约市，美国，9页。https: //doi.org/10.1145/3583131.3590442

1 引言

在本研究中，我们采用一种受PID启发的方法来调节基于阈值的群体中的智能体响应阈值。该群体规模固定、去中心化且不进行通信。在任意给定时刻，一个智能体最多只能执行测试问题中可能出现的四项任务中的一项。现有的动态阈值方法可以进行一次专门化，但可能难以重新专门化。我们的方法通过增强群体重新专业化的能力，帮助群体更有效地适应不断变化的任务需求。

去中心化群体具有鲁棒性和可扩展性，但由于没有领导者，群体很难实现共同目标。响应阈值模型是一种解决这一问题的简单方法。自然群体（如社会性昆虫）为这一方法提供了灵感 [4, 5, 25]。这一模型背后的理念简单而强大：每个智能体都有一组阈值，每项现存任务各对应一个阈值。如果某项任务刺激或任务需求的水平低于相应阈值，则相应行为发生的可能性较低；如果刺激高于相应阈值，则该行为更有可能发生 [4, 25]。因此，我们为每个智能体分配的阈值决定了系统的集体行为。我们希望根据当前的任务需求，为智能体恰当地分配阈值。任何系统都需要适应变化和新的任务需求，才能生存并发展。在基于响应阈值的系统中，这种适应取决于各智能体在实验过程中调整自身阈值的能力。如果某项任务当前有需求，而此前没有，那么群体就需要更多在该任务上阈值较低的智能体，才能有效应对。现有的阈值适应方法能够有效地针对初始任务需求集合实现专门化，但在任务需求发生变化时，往往难以重新专业化。

我们旨在寻找一种能够使智能体有效地进行专门化和重新专门化的方法。在解决这一问题时，控制回路可能会有所帮助。控制回路通过基于反馈持续调整系统，力求实现期望的输出。*PID*控制（比例 - 积分项 - 微分项）是一种流行且简单直接的控制回路 [6]。它广泛应用于各种应用场景，例如粒子生物医学应用 [9, 24], 、温度控制等过程控制 [35]以及机器人学 [37]。

PID控制器持续将系统的期望行为与其实际行为进行比较，然后利用该误差率改变系统的行为，使其更接近期望行为。这种改变取决于三个分量：比例分量根据当前误差率调整控制信号。积分分量考虑随时间累积的累积误差率，这有助于消除任何稳态误差。微分分量考虑误差率的变化。该分量有助于系统在面对突发变化时提升系统响应性。通过将PID控制器应用于我们的系统，我们基于这三个分量改变智能体的阈值。

我们在三种群体规模下的五类任务需求设置中测试了我们的方法。我们证明，与当前的动态阈值方法和固定阈值方法相比，我们的受PID启发的方法具有可扩展性，并能提升群体性能。

在满足以下条件的前提下，允许免费为个人或课堂用途制作本作品全部或部分内容的数字副本或纸质副本：不得为营利或商业利益而制作或分发副本，且副本首页必须附有本声明和完整引文。对于本作品中由作者以外的其他人拥有版权的组成部分，必须尊重其版权。注明出处后，可以摘引。若要以其他方式复制、再版、发布到服务器或分发至列表，则须事先获得特定许可和/或支付费用。请发送邮件至 permissions@acm.org 申请许可。*GECCO '23，2023*年*7*月*15*日至*19*日，葡萄牙里斯本 © 2023 版权所有归所有者/作者所有。出版权已授权给 ACM。ACM ISBN 979-8-4007-0119-1/23/07...$15.00 https://doi.org/10.1145/3583131.3590442

2 背景与相关工作

2.1 响应阈值模型

早期研究表明，固定响应阈值模型 [4, 10, 13,33]在静态环境和变化环境中都表现良好 [31]。我们认为，这类固定模型没有充分发挥这些系统的潜力；允许阈值根据环境或其他因素随时间变化，可以构建更高效的系统。这类变化可能是非反应式的，也可能是反应式的。在非反应式方法中，阈值是时间的函数。它们不取决于实验的局部或全局因素。一种受社会性昆虫启发的方法 [21]是年龄多态现象，在这种现象中，智能体针对任务的阈值或其范围会随着年龄增长而变化 [15, 26]。另一方面，反应式方法会在智能体对实验期间发生的某些情况作出反应时改变阈值。这些方法可以基于局部或全局因素。全局因素是指任务需求、执行特定任务的智能体数量等因素。智能体可能无法获取这些因素的信息，因此有时需要基于与其他智能体的通信来估计全局值 [14]。智能体在特定任务上的经验 [7, 25]是局部因素的一个例子。局部因素的重要实例之一是学习／遗忘率的使用 [7, 8, 18, 25]。当智能体执行任务并获得经验时，其阈值会减少一个固定值；当智能体在一个时间步内未执行某项任务而遗忘该任务时，其阈值会增加。这会形成一个正反馈回路，可能导致智能体卡在极高或极低的阈值上。因此，这些方法能够在早期阶段进行适应，但随着实验推进，其有效性可能会降低 [11, 12]。当所有任务并非一开始就被引入时，就会出现这一问题的一个例子。智能体会专门化于最初的任务，但在引入新任务后很难重新专业化。我们提出了一种新方法，使智能体能够进行专门化和重新专门化，而不会卡在极低或极高的阈值上。

2.2 PID控制器

闭环控制回路 是这样一种机制：系统的误差率定义为设定值（SP）与过程变量（PV）之间的差值，并对其进行持续计算。随后，控制器根据该误差率应用校正，以改善每个时间步的性能。闭环控制回路的一些示例包括PID控制器 [9, 24, 34, 35, 37], 模糊逻辑控制器 [2, 16], 模型预测控制器 [19, 20],和自适应控制器 [1, 22, 23]。

PID控制器为许多控制问题提供了简单的解决方案 [6]。PID控制器的简易性使其适用于大规模群体，因为随着群体规模的增大，为每个智能体配备高计算能力可能不可行且成本高昂。因此，人们更倾向于使用不需要高计算能力的简单控制器。PID控制器的框图如图1所示。

图 1 展示了设定值与过程变量之间的差值（即误差率）如何输入控制器。控制器由比例、积分项和微分项三个部分组成。这三个因素通过求和节点相加，随后由被控对象（即我们试图控制的系统）进行处理。然后重新计算校正后的过程变量

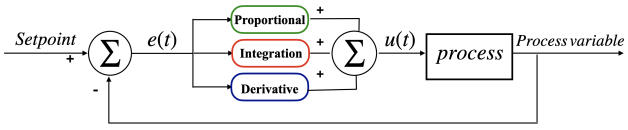


图1：标准PID控制器的框图

，并继续循环。给定设定值 SP 和过程变量 PV，误差率 $e(t)$ 可写为：

$$e(t) = SP(t) - PV(t) \tag{1}$$

在给定误差率 $e(t)$、P增益 K_P、I增益 K_I和D增益 K_D的情况下，PID控制函数 $u(t)$的输出计算如下：

$$u(t) = K_P.e(t) + K_I.\int_0^t e(\alpha)d\alpha + K_D\frac{de(t)}{dt} \tag{2}$$

增益 K_P、 K_I和 K_D 会根据问题设置发生变化，并通过整定方法确定。增益可以为零，这会导致某些项被消除。

比例项将控制器的响应与系统当前的误差率相关联。尽管这使系统具有响应性，但单独使用比例项（比例控制器）可能导致较长的调节时间和较大的稳态误差。

积分项通过考察累积的过去误差来发挥作用。单独使用积分项（积分控制器）可能会导致响应时间较长；不过，积分控制器的稳态误差小于比例控制器。积分因子还会带来另一个问题，即积分饱和问题。当积分因子产生的累积误差持续推动系统运行，而当前误差率已经很低时，就会发生积分饱和。因此，积分饱和会加剧误差，抵消系统的益处；不过，可以通过抗积分饱和方法解决这一问题。将比例控制器与积分控制器结合（比例积分控制器），既能提高系统响应性（相较于积分控制器），又能减小稳态误差（相较于比例控制器）。

微分项通过考察系统误差率的当前变化趋势来发挥作用。微分项通常不会单独使用，因为它会使系统极不稳定。它会与比例项结合（比例微分控制器），或与比例项和积分项结合（PID控制器）。微分项用于提高系统响应性。比例微分控制器和PID控制器的响应性高于比例控制器和比例积分控制器，这在存在突变的系统中可能很有帮助，但微分项会放大噪声，且无法消除稳态误差。

为了获得更直观的理解，请看一个例子：一架无人机希望悬停在距地球 L 的高度。如果我们只使用比例项，那么无人机到达高度 L后就会停止向上推力，随后下落。存在一个特定位置，此时无人机的推力恰好等于其重量，这就是稳态误差。积分项可以消除这一误差。稳态误差会随时间累积，促使无人机增加推力：只要存在误差，误差就会不断累积并迫使无人机继续推；然而，累积的误差可能会使无人机越过目标位置。我们还需要一个项来判断是否正在接近目标，这就是微分项。

鉴于上述局限性，一个能够应对大多数情况的控制器应包含全部三个项。

3 实验方法

3.1 测试平台设置

我们使用的测试平台是一个被可视化为集体跟踪问题的任务分配问题，常用于响应阈值研究 [29, 32, 33]。

我们的测试平台受蜜蜂体温调节的启发。蜂群能够在没有集中式控制器的情况下，随着时间推移共同控制蜂巢的温度。蜂巢的温度（一个一维向量）会在蜜蜂颤抖时升高，在蜜蜂拍翅时降低 [27]；每只蜜蜂都可以在两项相互对立的任务（拍翅或颤抖）之间进行选择。我们将其扩展到二维，并将其构建为一个集体控制二维跟踪问题。这一扩展使我们的模型能够描述更复杂的系统，也使可视化更加容易 [32]。

我们考虑二维向量空间中的一个移动目标和一个跟踪器。在每个时间步，跟踪器都应尽可能紧跟目标。系统性能以所有时间步中目标与跟踪器之间的平均距离来衡量。我们将系统中的误差率 定义为目标与跟踪器之间的距离。目标在二维空间中沿预定路径移动，并在每个时间步移动固定距离。跟踪器由智能体群共同控制，也就是说，每个智能体可以选择以下一种行动：向北推、向南推、向西推、向东推，或保持静止。所有智能体的行动会汇总起来，决定每个时间步的目标移动情况。智能体群采用去中心化方式，智能体之间互不通信。智能体根据各自的阈值和当前对应的任务需求来决定选择哪项任务。任务需求定义为每个时间步目标与跟踪器在各个方向上的差值。每个智能体i都有一组四个阈值$T_{i,\ north}$, $T_{i,\ south}$, $T_{i,\ east}$, $T_{i,\ west}$。如果某个方向上的任务需求超过该智能体在该方向上的阈值，智能体就会执行该任务；但如果存在多个任务的阈值低于刺激值，则会选择其中一项随机执行。我们将实验运行 500 个时间步，以便让我们的方法有时间趋于稳定。

尽管我们对问题的可视化形式看起来像是一个跟踪问题，而且我们也意识到已有非常高效的算法能够解决跟踪问题，但我们的研究目标并不是为跟踪问题寻找更高效的方法，而是寻找一种在去中心化任务分配问题中改变阈值的方法，使系统能够在变化环境和非变化环境中都有效运行。为此，我们需要一个测试平台，在其中可以轻松改变任务需求并清晰地将其可视化。在该测试平台中，我们可以通过改变所定义的目标路径，在每个时间步大幅改变任务需求。这些变化可以逐渐发生，也可以突然发生；可以沿多个方向或仅沿一个方向发生；也可以保持一切不变。这使得该测试平台非常适合我们的研究目的。例如，在之字形路径中，向东方的需求保持不变，而向北和向南的需求会交替突变。另一方面，我们还有S形曲线路径，这是一条周期性路径，向东方的需求保持不变，而需求会持续变化于北方和南方之间。利用这些路径，我们可以测试我们的方法在持续变化环境和突变环境中是否都有效。我们在五条路径上进行实验。

- 西：每个时间步中，只有对西向的恒定需求。选择这条路径是为了展示我们的系统如何应对不变的任务需求。
- 随机：每个时间步都会将一个从高斯分布 N (0.0, 1.0) 中随机抽取的角度加到当前目标方向上。在几乎所有情况下，随机路径都包含各个方向的需求。
- 急转：沿直线行进，并在每个时间步以一定概率随机转向。
- S形曲线：一种周期性路径，对东方任务的需求恒定，而对北和南的需求持续变化，类似于正弦路径。该路径需要所有任务，但对西向的需求非常小。• 之字形：一种对东方的需求恒定的周期性路径。对北和南的需求在一段时间内保持不变，然后突然改变，从而形成之字形模式。

我们在每次实验中运行 500 个时间步，以便 PID 有时间稳定并收敛。

3.2 受PID启发的方法

3.2.1 模型设置。 在我们的方法中，受PID控制回路启发，阈值会根据群体的误差率、微分项和积分项发生变化。

在我们的测试平台中，在给定目标和跟踪器位置的情况下，时间步 t时各个方向上的误差率 $e_{i,\ t}$ $i \in \{N,\ E,\ S,\ W\}$$Target_{x,\ t}$ $Target_{y,\ t}$和 $Tracker_{x,\ t}$ $Tracker_{y,\ t}$定义为：

$$e_{N,t} = Target_{y,t} - Tracker_{y,t} \quad \text{if } Target_{y,t} > Tracker_{y,t} \tag{3}$$

$$e_{S,t} = Tracker_{y,t} - Target_{y,t} \quad \text{if } Target_{y,t} < Tracker_{y,t} \tag{4}$$

$$e_{E,t} = Target_{x,t} - Tracker_{x,t} \quad \text{if } Target_{x,t} > Tracker_{x,t} \tag{5}$$

$$e_{W\,t} = Tracker_{x,\ t} - Target_{x,\ t} \text{如果 } Target_{x,\ t} < Tracker_{x,\ t} \tag{6}$$

否则它们为零。

在每个时间步中，给定比例因子 t、积分因子 F_P、微分因子 F_I、P增益 F_D、I增益 K_P和D增益 K_I，智能体 i针对任务 n的阈值 $T_{t,\ i,\ n}$ 可以通过以下方式计算：

$$T_{t,i,n} = T_{t-1,i,n} - K_P \times F_P - K_I \times F_I - K_D \times F_D \tag{7}$$

我们将时间步 t时 $i \in \{N, E, S, W\}$的比例因子$F_{P,i,t}$定义为：

$$F_{P,N,t} = e_{N,t} - e_{S,t} \tag{8}$$

$$F_{P,E,t} = e_{E,t} - e_{W,t} \tag{9}$$

$$F_{P,S,t} = e_{S,t} - e_{N,t} \tag{10}$$

$$F_{P,W,t} = e_{W,t} - e_{E,t} \tag{11}$$

该值表示各方向的误差率。根据误差率$e_{i,t}$的定义，在每个时间步中，北或南方向的误差率以及东方或西方向的误差率必须分别有一个等于零。

我们将时间步 t时给定 $i \in \{N, E, S, W\}$的积分因子$F_{I,i}$定义为：

$$F_{I,i,t} = \sum_{s=0}^{t-1} F_{P,i,s} \tag{12}$$

由于问题采用离散时间步长，因此积分分量以求和形式表示。

我们使用以下公式计算 $F_{D,\ i,\ t}$ 对于 $i \in \{N,\ E,\ S,\ W\}$ 的微分因子：

$$F_{D,i,t} = e_{i,t} - e_{i,t-1} \tag{13}$$

$F_{D,\ i,\ t}$ 表示每个方向上最近两个误差率之差。

图2展示了我们方法的框图。每个智能体 i 都有一个独立的控制器。系统计算目标与跟踪器之间的差值，并将其馈送至所有控制器。根据我们的方法修改阈值后，智能体决定是否对该特定任务采取行动。其决策可以是1或0。1表示智能体执行该任务，0表示智能体拒绝执行。所有智能体决策之和会更新跟踪器的位置，然后循环继续。

*3.2.2 PID*整定。 确定PID控制器的比例、积分项和微分因子的增益，对于系统的性能表现起着至关重要的作用 [6]。目前有多种整定方法，包括齐格勒-尼科尔斯方法 [38]。齐格勒-尼科尔斯方法是最简单的PID控制器整定方法之一。首先，将 K_D 和 K_I 设为零，然后逐渐增大 K_P，直到输出出现持续振荡，并将该增益记为 K_U，将其振荡周期记为 P_U。随后，根据齐格勒-尼科尔斯方法，K_P、K_I和 K_D 可表示为 [38]:

$$K_P = 0.6K_U \quad K_I = 1.2K_U/P_U \quad K_D = 0.075sK_U \times P_U \tag{14}$$

由于我们可能并不总是预先了解将要遇到的路径和任务需求，因此我们选择基于一条基本直线路径调整参数，并将相同的参数用于其他路径。

3.2.3 积分饱和。 积分分量和累积的误差率可以减小稳态误差，但这也有缺点。如果初始误差过大，即使当前误差率很低，实验开始以来累积的误差也可能使积分分量过大，进而降低性能。先前时间步累积的误差可能导致群体在没有必要时投入过多精力。已有多种方法被提出以解决这一问题 [17]。这些方法都试图对积分分量设定某种限制。对于方向 i，我们为积分分量设定了两个条件。第一，方向 i 上的误差率 $e(r)$ 应大于 0。第二，我们为积分分量设定一个饱和点，限制其最大值。这两个条件有助于减轻积分饱和的影响。

3.3 其他方法

为了分析我们受 PID 启发的方法的性能，我们将其与四种不同的阈值修改方法进行比较：一种静态方法（不修改阈值）和三种动态阈值模型。

每个智能体的四个初始阈值均从均匀分布中抽取。我们选择这种初始分布，是因为先前的研究 [30]表明，初始阈值服从均匀分布的群体，其性能优于初始阈值服从高斯分布、泊松分布和常数分布的群体。

我们将结果与之比较的第一个方法是 TD0。使用 TD0 时，阈值在整个实验过程中保持不变。该方法作为其他方法的基准。

第二种方法 TD1 的灵感来自响应阈值研究中最常用的方法之一：学习/遗忘方法 [25]。该方法的基本思路是，随着智能体在某项任务中积累经验，它们今后执行该任务的可能性应更高，而执行其他任务的可能性应更低。在时间步 t，如果智能体 i 执行任务 k，$\theta_{t,\ i,\ k}$ 可计算如下：

$$\theta_{t,i,k} = \theta_{t-1,i,k} - \epsilon \quad k \in \{N, E, S, W\} \tag{15}$$

对于智能体 i，在时间步t，其余所有任务阈值 $\theta_{t,i,j},\ j \neq k$ 均可表示为：

$$\theta_{t,i,j} = \theta_{t-1,i,j} + \psi \quad j \in \{N, E, S, W\} and\ j \neq k \tag{16}$$

使用这种方法，智能体可以专门执行符合当前任务需求的特定任务；但一旦阈值收敛，智能体就很难重新专门化以适应新的任务需求 [11, 12]。智能体往往会陷入阈值极高或极低的状态，我们称之为汇状态。

第三种方法 TD2 与 TD1 类似，因为它采用了前文所述的同一种学习/遗忘方法。两者唯一的区别在于，TD2 通过引入异质阈值范围来避免 TD1 方法中的汇状态问题。先前的研究表明，采用异质阈值范围有助于避免汇状态 [31]。在 TD1 中，所有智能体的阈值范围相同；而在 TD2 中，最小阈值从 $[0, 0.5]$ 中随机生成，最大阈值则从 $[0.5, 1]$ [31] 中随机生成。

第四种方法TD3与TD2非常相似，区别在于阈值范围是从[0,1]中随机抽取的。较大的值被指定为该范围的最大值，较小的值被指定为该范围的最小值。

我们希望将受PID启发的方法与上述方法进行比较，以了解其性能，并检验其能否避免汇状态以及有效地重新专门化。

4 结果与讨论

我们在直线路径、之字形路径、急转路径、S形曲线路径和随机路径上测试了我们的方法以及TD0、TD1、TD2和TD3，以评估其在各种任务需求变化下的有效性；同时，我们还在多种群体规模（50、100和500个智能体）下进行测试，以评估其可扩展性。与其他方法相比，我们的受PID启发的方法在所有路径和所有群体规模下均表现出更优的性能。

图3比较了不同群体规模和任务需求路径下不同阈值修改方法的误差率，误差条表示一个标准差。平均差异越小，性能越好。结果取100次运行的平均值。图(a)显示直线路径中的误差率，图(b)显示S形曲线路径中的误差率，图(c)显示随机路径中的误差率，图(d)显示尖锐路径中的误差率，图(c)显示之字形路径中的误差率。每个图的y轴表示系统在一次运行期间的平均误差率，该数值取100次独立运行的平均值。如前文所述，在我们的设置中，误差率是目标与跟踪器之间的差异。每个图的 x轴表示不同群体规模下的不同阈值修改方法（TD0、TD1、TD2、TD3和受PID启发的方法）。绿色表示群体规模为50，黄色表示群体规模为100，红色表示群体规模为500。图3表明，

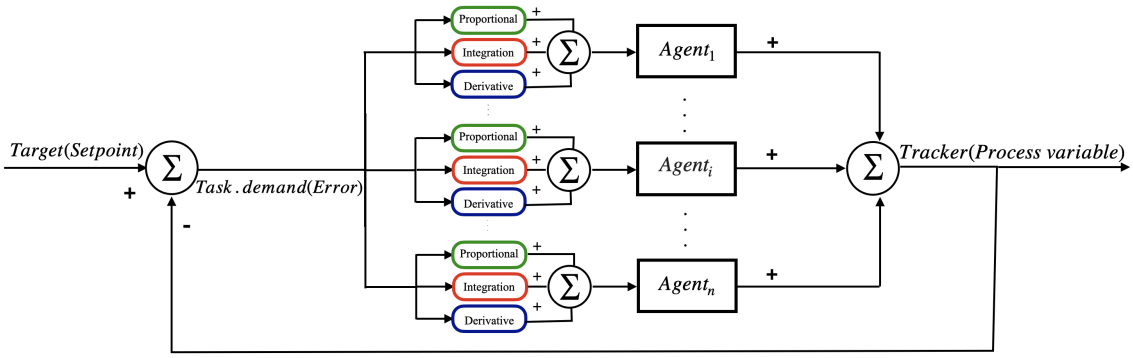


图2：我们受PID启发的方法的框图

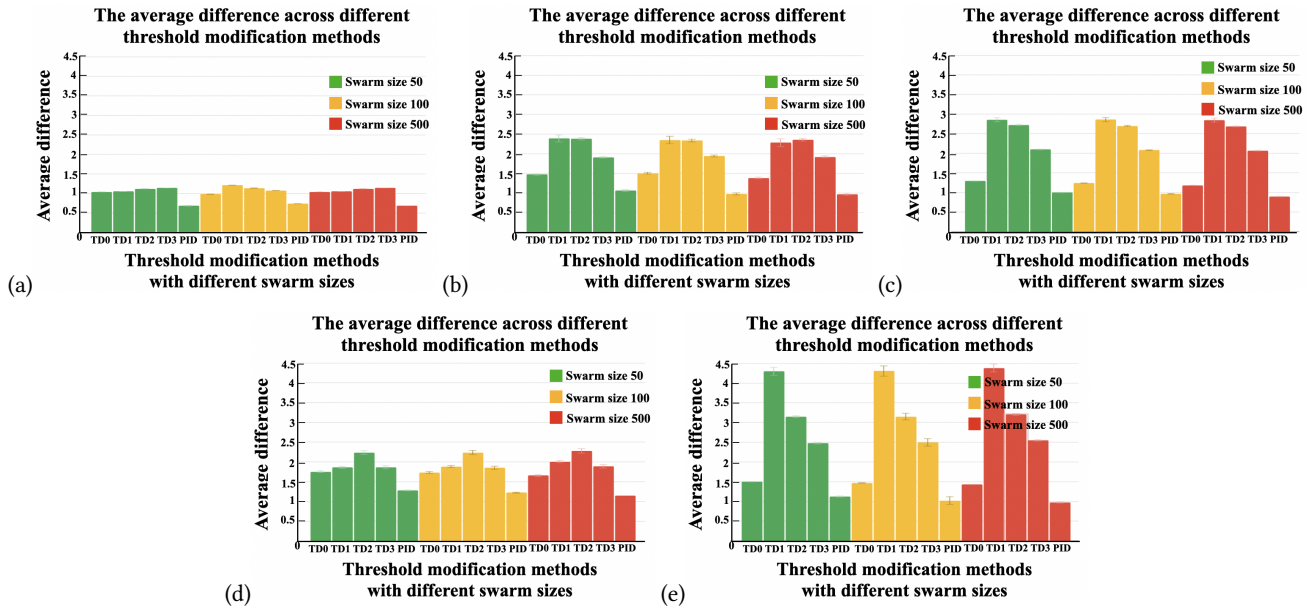


图3：对100次运行中目标与跟踪器之间的平均距离取平均值。绿色表示群体规模为50，黄色表示100，红色表示500，分别对应（a）直线路径（b）S形曲线路径（c）随机路径（d）之字形路径（e）尖锐路径

受PID启发的方法在各种路径和不同群体规模下始终优于其他方法。这表明，我们的方法对于未知路径而言是一种低风险的选择，并且具有可扩展性，这是群体系统算法的一个关键因素。

4.1 专业化分析

专业化对任何多智能体系统 [28] 都有益；我们都在运用专业化，从昆虫社会 [3] 到人类社会 [36]。专业化并不是一个容易定义的术语。即使在响应阈值研究中，对于何时将智能体称为在某项特定任务上实现了专业化，也没有公认的标准。在我们的系统中，为了更全面地比较各种方法，我们需要考察系统阈值如何变化，以及它们如何适应不同的任务需求。因此，如果某项任务对应的阈值是四个阈值中最低的，我们就称该智能体为这项任务的专家。该智能体 i，$S(i)$ 在时间步 step t 的专长，给定北向阈值 $T_{i,\ North}$、东向阈值 $T_{i,\ East}$、南向阈值 $T_{i,\ South}$ 和西向阈值 $T_{i,\ West}$，可写为：

$$S_t(i) = \arg\min\{T_{i,North}, T_{i,East}, T_{i,South}, T_{i,West}\} \quad (17)$$

当任务需求发生显著变化时，专门化于特定任务的智能体数量具有较高方差，表明系统响应性较高。当任务需求保持不变时，较低的方差表明系统稳定性较高。

为了更全面地比较这些方法，我们考察了单次运行的示例，以及智能体专门化的变化情况。图4至图8展示了智能体的专业化程度 $S_t(i)$ 随时间在不同路径中的变化。所有图中的 y 轴表示实验中的时间步。 x 轴表示 $Agent_0$ 至 $Agent_{99}$。图中每种颜色代表智能体的专门化

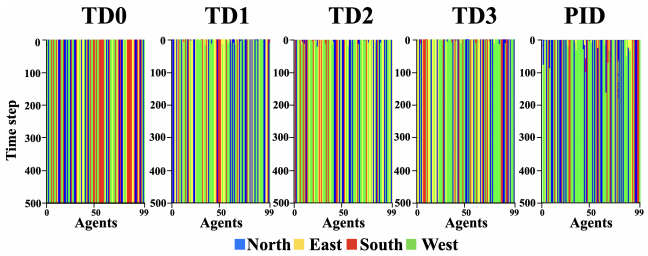


图4：不同阈值自适应方法的直线路径专门化比较

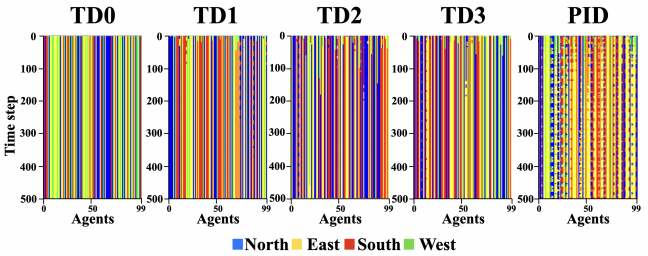


图5：不同阈值自适应方法的S形曲线专门化比较

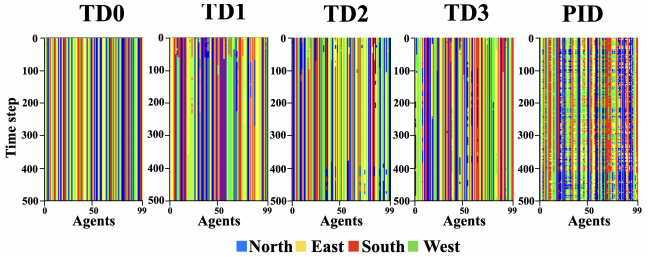


图6：不同阈值适应方法下随机路径的专门化比较

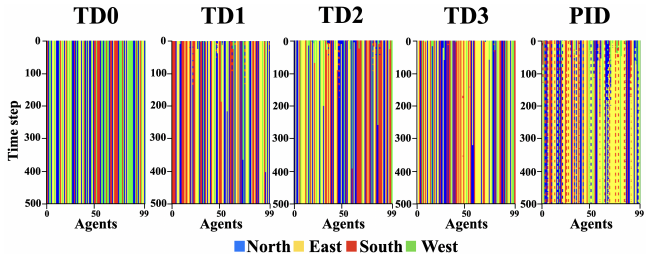


图7：不同阈值适应方法下之字形专门化比较

在该时间步的状态。蓝色表示北方专门化；黄色表示东方；红色表示南方；绿色表示西方。

4.1.1 无变化（直线路径）。我们从最简单的路径开始。直线路径具有恒定的西方任务需求。正如图3所示，在所有群体规模下，受PID启发的方法都优于TD0、TD1、TD2和TD3。在图4中可以看到，由于所有智能体的初始阈值都是随机设置的，因此智能体的专门化，$S(i)$，在最初的几个时间步中呈现出随机模式。在TD0方法中，阈值是固定的，因此我们看到专门化随时间没有变化，这符合预期。

在TD1、TD2、TD3和受PID启发的方法中，我们可以看到，一些智能体在最初的时间步中将其专门化，$S(i)$，从其他任务转向西；然而，我们发现，采用受PID启发的方法时，具有西方专门化的智能体比其他方法更多。在采用受PID启发的方法进行的这次特定运行中，专门化于西的智能体数量的方差为13。00，高于0、3。06、4。33和1。97，这些分别是TD0、TD1、TD2和TD3中西方专门化智能体的方差。在最初的时间步中，智能体逐渐专门化于西向，而更高的方差值表明，采用受PID启发的方法时，西向专门化发生得更多。如果只考虑最后100个时间步，所有方差都变为零，这表明智能体经过一段时间后会趋于稳定。由于直线路径的任务需求是恒定的，因此这种稳定化符合预期。

4.1.2 恒定变化（*S*形曲线路径和随机路径）。其次，我们分析任务需求逐渐且持续变化时的路径，包括S形曲线路径和随机路径。就目标与跟踪器之间的平均距离而言，受PID启发的方法优于其他方法。

图5描绘了S形曲线路径的专门化图。TD0具有随时间保持不变的专门化。我们可以看到，其他方法在较早的时间步进行专门化和重新专门化；然而，随着实验的推进，TD1、TD2和TD3重新专门化的能力逐渐减弱。它们会陷入先前的专门化状态，无法进行适应。然而，受PID启发的方法能够适应不断变化的任务需求。我们可以看到，其对应智能体的专门化变化呈现出周期模式，这与S形曲线的周期模式一致。图6展示了随机路径的专门化图。同样，我们可以看到，与受PID启发的方法相比，TD1、TD2和TD3更难重新专业化。

由于S形曲线路径和随机路径中的任务需求持续变化，采用受PID启发的方法时，专业分工始终不会稳定下来。受PID启发的方法在所有任务需求下的方差都更高；例如，在S形曲线路径中，采用受PID启发的方法时，北方专业人员的方差为34.69，而其他方法的方差分别为0、1.35、2.87和0.69。对于随机路径，采用受PID启发的方法时，方差为67.52，而其他方法的方差分别为0、2.40、9.512和5.06。如果只考虑最后100个时间步，方差与考虑全部500个时间步时的结果相近。这表明智能体不会陷入汇状态，并能在整个实验过程中保持响应能力。

4.1.3 突变（之字形路径和尖锐路径）。最后，我们分析一段时间内保持不变、随后发生突变的路径。之字形模式具有恒定的东方任务需求，但北方和南方的需求会在峰值点周期性变化。在图 7 中，我们再次看到，TD1、TD2 和 TD3 在早期阶段会专门化并重新专门化，但随着时间推移，它们的响应性逐渐降低，而受PID启发的方法仍能继续适应。

对于尖锐路径，任务需求保持不变，然后突然随机转向。在图 8 中，我们再次看到，即使对于

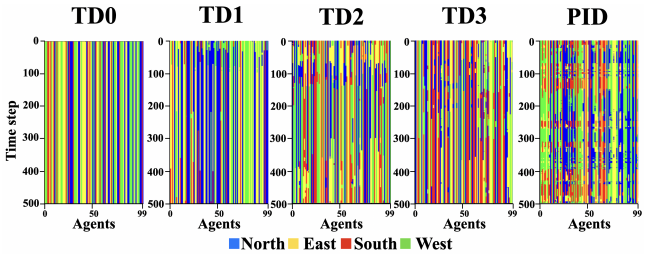


图 8：不同阈值自适应方法在急转路径上的专门化比较

非周期性路径，受 PID 启发的方法也比其他方法具备更强的重新专业化能力。在之字形路径和尖锐路径中，任务需求会保持一段时间不变，然后突然发生变化。如果考虑 500 个时间步，受 PID 启发的方法中所有任务的专业人员方差都更高。例如，在之字形路径中，受 PID 启发的方法在南向的专业人员数量方差为 36.79，而其他方法分别为 0、1.47、2.53 和 0.28。如果只考虑最后 100 个时间步，受 PID 启发的方法的方差会显著降低。例如，在尖锐路径中，南向专长在 500 个时间步内的方差为 43.61，而在 100 个时间步内为 8.02。这是因为尖锐路径和之字形路径中的任务需求会保持一段时间不变，然后突然发生变化。在任务需求保持不变的时期，方差较低，智能体的专业分工变化也较小，这表明系统在恒定任务需求下具有稳定性。

为了说明专门化和重新专门化的有效性，我们讨论一个来自之字形路径的示例。我们选择之字形路径，是因为其中有明确的点表示任务需求发生突变。图 9 展示了采用不同阈值修改方法时，各项任务对应的专门化智能体数量。为使图示更清晰，我们选取较短的时间间隔 [400,500]。x 轴表示时间，y 轴表示专门从事以下任务的智能体数量：(a) 西、(b) 南方、(c) 北和 (d) 东方。蓝色代表 TD0；红色代表 TD1；黄色代表 TD2；绿色代表 TD3；橙色代表 PID。在之字形路径中，北和南方的任务需求周期性交替。这种相同的模式可见于图 9c 和图 9b。之字形路径首先朝东北方向前进，这解释了为什么图 9c 和图 9e 的起始处会出现一个凸起。智能体最初专门从事北向和东向任务，但南方任务需求增加后，一些原先专门从事北向和东向任务的智能体转而专门从事南方任务。这就是北向和东向任务的智能体数量呈现相似起伏的原因。西方专门化智能体的数量变化很小，因为该方向没有任务需求。这些微小变化是由于任务需求突变时，系统试图修正峰值点处的小幅过冲。与其在直线路径上整定参数或采用更精确的整定方法，不如直接针对之字形路径整定参数，这样可以减少这些过冲。这些图表明，智能体的专门化与任务需求相符，而且 PID 响应更灵敏，能够实现专门化和重新专门化。

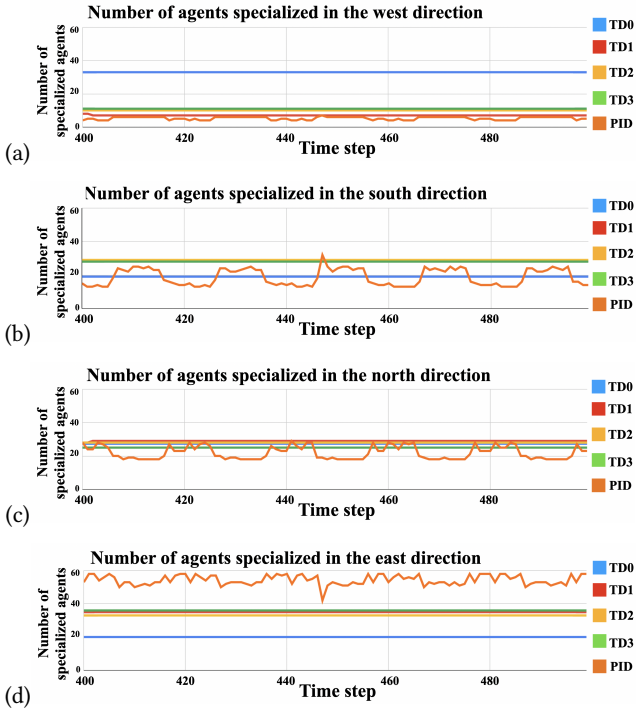


图 9：从时间步 400 到 500，在任务中采用不同阈值修改方法的专门化智能体数量：(a) 西向 (b) 南向 (c) 北向 (d) 东向

5 结论

在本研究中，我们测试了一种受 PID 启发的新型阈值修改方法在去中心化、无通信的基于阈值的群体系统中的有效性。我们在二维向量空间中的集体跟踪问题上测试了该方法。我们考虑一个目标和一个跟踪器，它们在每个时间步都可以移动固定距离，而跟踪器则由智能体群集体控制。以往的阈值修改方法能够有效地实现初始专门化，但当需求发生变化时，智能体很难重新专门化，因而无法适应。我们的方法基于 PID 控制回路因子，即误差率、误差率的微分项和误差率的积分项。在我们的系统中，误差率定义为目标与跟踪器之间的距离。每个智能体都有一个独立的控制器，用于修改该智能体的阈值。结果表明，无论群体规模如何，我们的方法在所有路径上都优于其他所讨论的方法。在任务需求恒定的情况下，智能体能够达到稳定的专门化；在任务需求发生变化时，智能体能够进行专门化和重新专门化，而不会陷入停滞。我们的方法不受汇状态影响，因此能够在整个仿真过程中针对不断变化的任务需求进行重新专门化。

6 致谢

本研究得到美国国家科学基金会 IIS1816777 号资助。

参考文献

[1] Brian DO Anderson 和 Arvin Dehghani。2008年。自适应控制的挑战——过去、现在与未来。《控制年度评论》32，2（2008年），123–135。[2] Hamid R Berenji。1992年。模糊逻辑控制器。《智能系统中的模糊逻辑应用导论》（1992年），69–96。[3] Samuel N Beshers 和 Jennifer H Fewell。2001年。社会性昆虫中的劳动分工模型。《昆虫学年度评论》46，1（2001年），413–440。[4] Eric Bonabeau、Guy Theraulaz 和 Jean-Louis Deneubourg。1996年。用于调节昆虫社会劳动分工的固定阈值模型的定量研究。《伦敦皇家学会学报B辑：生物科学》263，1376（1996年），1565–1569。[5] Eric Bonabeau、Guy Theraulaz 和 Jean-Louis Deneubourg。1998年。昆虫社会中的固定响应阈值与劳动分工。《数学生物学公报》60，4（1998年），753–807。[6] Rakesh P Borase、DK Maghade、SY Sondkar 和 SN Pawar。2021年。PID控制、整定方法及其应用综述。《国际动力学与控制杂志》9（2021年），818–827。[7] Mike Campos、Eric Bonabeau、Guy Theraulaz 和 Jean-Louis Deneubourg。2000年。社会性昆虫中的动态调度与劳动分工。《自适应行为》8，2（2000年），83–95。[8] Vincent A Cicirello 和 Stephen F Smith。2003年。通过类黄蜂智能体实现资源的分布式协调。《计算机科学讲义》（2003年），71–80。[9] Satoru Isaka 和 Anthony V Sebald。1993年。动脉血压调节的控制策略。《IEEE生物医学工程汇刊》40，4（1993年），353–363。[10] Anshul Kanakia、Behrouz Touri 和 Nikolaus Correll。2016年。将信息受限的多机器人任务分配建模为全局博弈。《群体智能》10（2016年），147–160。[11] Vera A Kazakova 和 Annie S Wu。2018年。专业化与重新专业化：赫布学习在动态环境中的影响。载于《FLAIRS会议》。354–359。[12] Vera A Kazakova、Annie S Wu 和 Gita R Sukthankar。2020年。通过遗忘强化阈值使群体重新专业化。《群体智能》14（2020年），171–204。[13] Michael JB Krieger 和 Jean-Bernard Billeter。2000年。职责召唤：由最多十二个移动机器人组成的群体中的自组织任务分配。《机器人学与自主系统》30，1-2（2000年），65–84。[14] Wonki Lee 和 DaeEun Kim。2019年。调节群体机器人系统中任务分配的自适应方法。《群体与进化计算》44（2019年），1108–1118。[15] Daniel Merkle 和 Martin Middendorf。2004年。社会性昆虫阈值强化模型中的动态多态行为与任务竞争。《自适应行为》12，3-4（2004年），251–262。[16] Costas P Pappis 和 Ebrahim H Mamdani。1977年。用于交通路口的模糊逻辑控制器。《IEEE系统、人、与控制论汇刊》7，10（1977年），707–717。[17] Youbin Peng、Damir Vrančić 和 Raymond Hanus。1996年。抗积分饱和、无扰切换与条件切换综述。《IFAC会议论文集》29，1（1996年），1524–1529。[18] Richard Price 和 Peter Tiňo。2004年。针对其他去中心化多智能体策略评估自适应自然启发式任务分配。载于《自然启发的并行问题求解——PPSN VIII：第八届国际会议，英国伯明翰，2004年9月18日至22日。会议论文集8》。Springer，982–990。[19] James B Rawlings。2000年。模型预测控制教程概述。《IEEE控制系统杂志》20，3（2000年），38–52。[20] Mahdi Razzaghpour、Shahriar Shahram、Rodolfo Valiente 和 Yaser P Fallah。2021年。通信丢失对基于MPC的协同自适应巡航控制和编队行驶的影响。载于《2021年IEEE第94届车辆技术会议（VTC2021-Fall）》。IEEE，01–07。[21] Gene E Robinson。1987年。保幼激素对蜜蜂年龄多态行为的调节。《行为生态学与社会生物学》20（1987年），329–338。[22] DE Seborg、Thomas F Edgar 和 SL Shah。1986年。过程控制的自适应控制策略：综述。《AIChE杂志》32，6（1986年），881–913。[23] Shahriar Shahram 和 Yaser Pourmohammadi Fallah。2023年。在配备自适应巡航控制器的电动汽车能量优化中利用速度信息预测。技术报告2023-01-0685。SAE技术论文。https: //doi.org/ 10 4271 2023 01 0685 。/ -- JB Slate 和 LC Sheppard。1982年。通过药物输注自动控制血压。《IEE学报A辑（物理科学、测量与仪器、管理与教育、评论）》129，9（1982年），639–645。[25] Guy Theraulaz、Eric Bonabeau 和 JN Denuebourg。1998年。响应阈值强化与昆虫社会中的劳动分工。《伦敦皇家学会学报B辑：生物科学》265，1393（1998年），327–332。[26] Jakob S Vesterstrom、Jacques Riget 和 Thiemo Krink。2002年。粒子群优化中的劳动分工。载于《2002年进化计算大会论文集：CEC'02（目录号02TH8600）》第2卷。IEEE，1570–1575。[27] Anja Weidenmüller。2004年。熊蜂（Bombus terrestris）群体巢穴气候的控制：扇风反应中的个体间变异与自我强化。行为生态学15，1（2004年），120–128。[28] Andrew Whiten、Dora Biro、Nicolas Bredeche、Ellen C Garland 和 Simon Kirby。2022年。动物、人类和机器中集体知识与累积文化的出现。，20200306页。[29] Annie S Wu 和 Vera A Kazakova。2017年。任务考虑顺序对使用时变响应阈值进行去中心化任务分配的影响。载于第三十届国际*FLAIRS*会议。[30] Annie S Wu、David H Mathias、Joseph P Giordano 和 Anthony Hevia。2020年。响应阈值分布对去中心化群体动态劳动分工的影响。载于第三十三届国际*FLAIRS*会议。[31] Annie S Wu 和 H David Mathias。2020年。动态响应阈值：异质范围在促进专业化的同时，减轻向汇状态的收敛。载于群体智能：第十二届国际会议，*ANTS 2020*，西班牙巴塞罗那，*2020*年*10*月*26*日至*28*日，论文集*12*。Springer，107–120。[32] Annie S Wu、H David Mathias、Joseph P Giordano 和 Arjun Pherwani。2021年。集体控制作为去中心化任务分配测试平台。技术报告。技术报告CS-TR-21-01。中佛罗里达大学。[33] Annie S Wu 和 Cortney Riggs。2018年。智能体间变异改进去中心化动态任务分配。。载于*FLAIRS*会议。366–369。[34] Zhenglong Xiang、Daomin Ji、Heng Zhang、Hongrun Wu 和 Yuanxiang Li。2019年。用于粒子群优化算法的简单基于PID的策略。信息科学502（2019年），558–574。[35] Toru Yamamoto 和 SL Shah。2004年。多变量自整定PID控制器的设计与实验评估。*IEE*控制理论与应用学报151，5（2004年），645–652。[36] Xiaokai Yang 和 Siang Ng。1998年。专业化与劳动分工：综述。Springer。[37] Hong Zhang、G Trott 和 RP Paul。1990年。机器人操作臂插值关节轨迹的最小延迟PID控制。*IEEE*工业电子学汇刊37，5（1990年），358–364。[38] John G Ziegler 和 Nathaniel B Nichols。1942年。自动控制器的最佳设置。美国机械工程师学会汇刊64，8（1942年），759–765。