

# 第十七章 基于混合智能的控制

在之前，我们已经讨论了大量的基于各种智能技术的智能控制算法。正所谓“尺有所短，寸有所长”，尽管这些算法各有千秋，在应对更复杂的控制问题时，独立的智能算法甚至仅仅依靠智能算法往往已经无法完全应付了。很自然的，我们可以考虑将多个智能技术集成起来，或者更进一步，我们可以考虑将智能技术和生物智能混合起来，从而形成基于混合智能的控制。

## 17.1 混合智能概述

### 17.1.1 何为混合智能

现在学术界对混合智能暂时还没有一个被广泛接受的定义，但是我们可以先从字面上看。“混合智能”是“混合”不同类型的“智能”，它的反面是“单一智能”或者“单纯智能”。所以混合智能的关键在于把生物或人类的认知能力或人类认知模型引入人工智能，从而混合多种智能技术，混合单纯的人工智能和开放灵活的人类智能。从某种意义上来说，混合的智能很有可能是智能的最终形态。

大体上，混合智能的两种表现形式是“基于认知计算的混合增强智能”和“人在回路的混合增强智能”。前者是指在智能系统中引入各种受生物启发的计算智能技术，如本书前面一些章节提到的模糊系统、神经网络系统、进化遗传算法等技术。而后者则将人的作用直接引入到智能系统中，形成人在回路甚至以人为中心的混合智能。

### 17.1.2 为何混合智能

正如本章开头提到的，我们需要混合智能的根本原因在于处理复杂的问题时，单一的智能技术，或者仅仅靠人工智能技术已经不够同时应付系统与环境的 uncertain 和开放性了。

反过来，如果开发“基于认知计算的混合增强智能”，那么如西安交通大学的郑南宁院士所言，我们可以“通过模仿生物大脑功能提升计算机的感知、推理和决策能力的智能软件或硬件，以更准确地建立像人脑一样感知、推理和响应激励的智能计算模型，尤其是建立因果模型、直觉推理和联想记忆的新计算框架”。当前模仿生物大脑功能或受生物启发的计算智能技术有模糊系统、神经网络系统、进化系统、学习系统、推理系统，等等。混合这些计算智能技术，能取长补短，从而更好地应付复杂的控制问题。

更进一步，如果开发“人在回路的混合增强智能”，我们可以克服当前人工智能相对于人类在高级认知功能的劣势，以便更好地发挥其在搜索，计算和存储上的优势。最终通过协同人类智能对不确定开放性问题的应对能力和机器智能对较简单系统的快速反应能力，如果我们让这两者相互协作，相互学习，共同执行，就能取得放大的智能效果。

### 17.1.3 基于混合智能的控制

基于混合智能的控制是指在应对复杂控制问题时采用混合智能的方法。相对于混合智能的两种表现方式，我们大体也把混合智能控制分为两大类：其中第一大类是混合两种或者两种以上生物启发智能技术的混合控制；第二类则是考虑人在回路或者人机协同的人机混合智能控制。下一节，我们先看看混合计算智能技术的控制。

## 17.2 混合计算智能技术的控制

### 17.2.1 各种计算智能技术的互补性

计算智能是一系列由自然和生物启发的处理复杂问题的计算技术。这类技术往往能处理传统建模或者数学方法较难处理的问题。常见的计算智能技术包括有：模糊系统、神经网络、进化计算、概率推理系统，等等。但是如果考察这些技术的优缺点，可以得到表 17.1。

表 17.1 同时研究人与机器的学科领域

	模糊系统	神经网络	进化计算	概率推理系统
专家知识的利用	强	弱	弱	强
可理解性	强	弱	一般	较强
处理不确定性	强	一般	一般	强
学习能力	弱	强	一般	较强
自适应性	弱	强	强	较强
鲁棒性	强	较强	较强	强
优化能力	弱	一般	强	一般

从表 17.1 我们可以发现，没有任何计算智能技术是只有优点而没有任何缺点的。同时，我们也可以发现，不同的计算智能技术往往包含有互补的优缺点。比如说，模糊系统对人类知识的表达和利用能力较强，但是其对系统的自适应和学习能力较弱。反过来，神经网络系统对人类知识的利用和可理解性较弱，但是其自适应和学习能力很强。自然的，我们可以考虑将神经网络和模糊系统混合起来，设计一种既能充分利用人类知识又能根据历史数据学习的神经模糊系统。再考虑到，进化计算方法如遗传算法的优化能力，我们还可以利用遗传算法来优化神经模糊控制系统。下面我们看两个例子。

### 17.2.2 神经模糊控制

将模糊系统和神经网络集成起来有多种方式。比如说，我们可以将神经网络中的权重模糊化，从而得到模糊神经网络。但更为常见的是将模糊系统用一个神经网络表达出来，形成所谓神经模糊系统。本小节将介绍一种能将模糊系统和神经网络一一对应的神经模糊系统<sup>[1]</sup>。

## 17.2.2.1 模糊系统和神经网络——对应的神经模糊系统

典型的模糊系统由输入、模糊化、模糊推理、解模糊和输出五部分组成（参见图 17.1）。

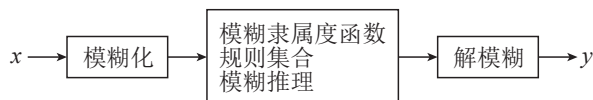


图 17.1 模糊推理控制系统的结构

模糊系统输入是个  $n$  维向量  $[x_1, x_2, \dots, x_n]$ 。其中每个一维输入  $x_i$  是一个语言变量 (Linguistic Variable) 且由  $m_i$  个词 (Linguistic Term) 也就是  $\{S_i^1, S_i^2, \dots, S_i^{m_i}\}$  描述, 其中  $S_i^j (j = 1, 2, \dots, m_i)$  是一个模糊集合表达的的词。出于简便, 模糊集合  $S_i^j$  相应的隶属度函数也记为  $S_i^j$ 。模糊系统输出量  $y$  也是由一组  $m_y$  个词  $\{B^1, B^2, \dots, B^{m_y}\}$  描述, 其中  $B^j$  是定义在论域  $U_y$  上的一个模糊集合, 相应的隶属度函数也记为  $B^j$ 。

值得特别指出的是, 为了方便我们最后对输出进行解模糊处理, 我们将输出值的论域取为有限个 ( $n_y$  个) 离散值。也就是论域  $U_y = u_1, u_2, \dots, u_{n_y}$ 。相应的描述输出变量的词隶属度函数变成了离散函数:  $B^j = \{w_{B^j1}/u_1, w_{B^j2}/u_2, \dots, w_{B^j n_y}/u_{n_y}\}$ 。举一个简单的例子, 若  $U_y$  取值范围为  $[0, 1]$ ,  $n_y = 9$ , 就可以设计输出的论域为  $\{u_1 = 0, u_2 = 0.125, u_3 = 0.25, u_4 = 0.375, u_5 = 0.5, u_6 = 0.625, u_7 = 0.75, u_8 = 0.875, u_9 = 1\}$ 。这样对于  $[0, 1]$  上的一个三角形的隶属度函数:

$$u = 1 - 2|a - 1/2|, \quad a \in [0, 1]$$

可以将其近似为离散的隶属度函数

$$u = \{0/u_1, 0.25/u_2, 0.5/u_3, 0.75/u_4, 1/u_5, 0.75/u_6, 0.5/u_7, 0.25/u_8, 0/u_9\}$$

模糊推理部分的行为通过以下  $R$  个 IF-THEN 规则组成的规则库描述:

规则 1: IF  $x_1$  is  $S_1^{k_{11}}$  and ... and  $x_n$  is  $S_n^{k_{n1}}$  THEN  $y$  is  $B^{c1}$

.....

规则  $R$ : IF  $x_1$  is  $S_1^{k_{1R}}$  and ... and  $x_n$  is  $S_n^{k_{nR}}$  THEN  $y$  is  $B^{cR}$

对给定的输入量采用最大最小合成方法, 可得到规则  $r$  的适用度 (Firing Strength) 为:

$$a_r = S_1^{k_{1r}}(x_1) \wedge S_2^{k_{2r}}(x_2) \wedge \dots \wedge S_n^{k_{nr}}(x_n), \quad r = 1, \dots, R$$

其中,  $\wedge$  是取交操作。

结合蕴涵推理, 如果系统输入是  $[x_1, x_2, \dots, x_n]$ , 每一条模糊规则的输出是模糊集合  $B_{c_j}$ , 其隶属度函数为:

$$B_{c_j}(y) = a_j \wedge B^{c_j}(y), \quad (j = 1, 2, \dots, R)$$

从而输出量总的模糊集合为  $B = \bigvee_{j=1}^R B_j$  (其中  $\vee$  是取并操作)。如果取交操作应用代数积:  $x \wedge y = xy$ , 取并操作应用有界和:  $x \vee y = \min(1, x + y)$ 。再考虑到输出  $y$  的离散取值空间为  $U_y = u_1, u_2, \dots, u_{n_y}$ 。我们有:

$$B_{c_j}(y) = \{a_j w_{B_{c_j}1}/u_1, a_j w_{B_{c_j}2}/u_2, \dots, a_j w_{B_{c_j}y}/u_y\}$$

最后在解模糊部分，采用中心法（Center-of-Area, COA）进行清晰化处理，就可以求得输出  $y$  的清晰化量为：

$$y = \frac{\sum_{i=1}^{n_y} u_i B(u_i)}{\sum_{i=1}^{n_y} B(u_i)} \quad (17.1)$$

其中  $B(u_i) = \bigvee_{j=1}^R B_j(u_i) = \sum_{j=1}^R a_j w_{B^j i}$ 。

对于刚刚描述的这个模糊系统，如果我们定义好隶属度函数和推理规则，我们可以很快地从输入推理出输出。而且这个系统能比较好地包含领域专家提供的知识如 IF—THEN 规则。但是这个系统的自适应能力还有待提高，考虑到神经网络系统的灵活性，特别是针对历史数据的学习能力，我们构筑一个 5 层神经网络系统与前面的模糊系统一一对应。

不失一般性，将模糊推理系统作如下设置：输入数为  $n=2$  个： $x_1, x_2$ ，它们各由  $m_i=2$ ，( $i=1,2$ ) 个词描述，其中描述  $x_1$  的 2 个词的是： $s_1^1, s_1^2$ ；描述  $x_2$  的 2 个语言变量是： $s_2^1, s_2^2$ ；系统的输出还是  $y$ ，由  $m_u=4$  个词  $B^{c_i} = \{w_{R^{c_i}1}/u_1, w_{R^{c_i}2}/u_2, w_{R^{c_i}3}/u_3\}$  ( $c_i=1,2,3,4$ ) 描述。其中每个词的离散取值空间  $U_y = u_1, u_2, u_3$ ，( $n_y=3$ ) 已取定。模糊规则库包含有  $R=4$  条规则：

规则 1：IF  $x_1$  is  $s_1^1$  AND  $x_2$  is  $s_2^1$  THEN  $y$  is  $B^1$ ；

规则 2：IF  $x_1$  is  $s_1^1$  AND  $x_2$  is  $s_2^2$  THEN  $y$  is  $B^2$ ；

规则 3：IF  $x_1$  is  $s_1^2$  AND  $x_2$  is  $s_2^1$  THEN  $y$  is  $B^3$ ；

规则 4：IF  $x_1$  is  $s_1^2$  AND  $x_2$  is  $s_2^2$  THEN  $y$  is  $B^4$ ；

那么与这个模糊推理系统一一对应的神经网络系统的具体结构图如图 17.2 所示：




图 17.2 相应神经网络的结构

下面逐层分析每个神经元的输入输出以及和模糊推理系统的一一对应关系：

第一层是输入层。这一层共有  $m_1 + m_2 = 4$  个神经元，它们对应着描述模糊推理系统的 2 个输入的 4 个词。每个神经元的输入是  $x_1$  或  $x_2$ ，输出的是相应的描述输入的词的隶属度值  $S_i^j$  ( $i=1,2; j=1,2$ )。

第二层是规则层。这一层共有  $R=4$  个神经元，每个神经元对应模糊推理系统的一条规则。第  $r$  个神经元的输入是第  $r$  条规则的 IF 部分的各个词的隶属度值  $S_1^{k1r}$  和  $S_2^{k2r}$ ，输出的是第  $r$  条规则的适应度：

$$a_r = S_1^{k_{1r}}(x_1)S_2^{k_{2r}}(x_2), r = 1, \dots, R.$$

第三层是输出词层。这一层共有  $n_y = 3$  个神经元, 连接它们的权值对应着描述  $y$  的词。第  $i$  个神经元的  $R$  个输入是  $a_r (r = 1, \dots, R)$ , 连接权是  $w_{R^{ci}} (r = 1, \dots, R)$ , 输出的是:

$$B(u_i = \sum_{j=1}^R a_j w_{B^{ci}}), (i = 1, 2, 3)$$

第四层是正规化层。这一层与第三层有相同多神经元, 第  $i$  个神经元的输入是  $B(u_i)$ , 输出是:

$$\bar{B}(u_i) = B(u_i) / \sum_{i=1}^{n_y} B(u_i) \text{ (此处 } n_y = 3 \text{)}$$

最后一层是输出层。这一层只有一个神经元, 它的输入为前层每个神经元的输出  $\bar{B}(u_i)$ , 连接权是  $u_i$ , 输为 (此处  $n_y = 3$ ):

$$y = \sum_{i=1}^{n_y} \bar{B}(u_i) = \sum_{i=1}^{n_y} u_i B(u_i) / \sum_{i=1}^{n_y} B(u_i) \quad (17.2)$$

比较式 17.2 和式 17.1, 综合神经网络各层的构造, 可以发现构造的神经网络系统与前面介绍的模糊系统完全一一对应。但神经网络系统的突出特点是容易学习, 所以通过一些训练样本来训练上述神经网络系统, 可以学习与优化  $w_{B^{ci}} (i = 1, \dots, m_v; j = 1, \dots, n_v)$  以及  $S_i^j (i = 1, \dots, n; j = 1, \dots, m_i)$  中的各个参数 {注意我们并没有具体指定过  $S_i^j$  的形式, 如果  $S_i^j$  是铃形函数即  $S_i^j = \exp[-(x - c_{ij}^2)/\delta_{ij}^2]$ , 那么它的参数就是  $c_{ij}, \delta_{ij}$ }。由于神经网络系统和模糊系统的一一对应性, 学习优化了神经网络的参数等价于学习优化了模糊系统中的模糊隶属度函数。

### 17.2.2.2 神经模糊系统的训练

现在我们假设, 有可供训练用的  $p$  组历史输入输出数据对  $\{(x^1, y^1), \dots, (x^p, y^p)\}$ , 对输入  $x^j$  应用神经模糊系统, 令从公式 17.1 得到的系统输出是  $\bar{y}^j$ 。那么系统的误差是  $E = \sum_{i=1}^p |y^i - \bar{y}^i|^2$ 。为了最小化系统误差, 我们应用梯度下降法, 可以得到各个参数  $C$  的调节公式如下:

$$C_{new} = C_{old} + h \times dE/dC \quad (17.3)$$

其中,  $h$  是小常数,  $dE/dC$  是参数  $C$  关于  $E$  的梯度。

例如, 参数  $C$  为描述输出的词的离散隶属度函数,  $w_{B^{ij}}$  时有:

$$w_{B^{ij}new} = w_{B^{ij}old} + h \times dE/dw_{B^{ij}} = 2 \sum_{i=1}^p (y^i - \bar{y}^i) d\bar{y}^i/dw_{B^{ij}}$$

其中,  $d\bar{y}^i/dw_{B^{ij}} = a_i \sum_{i=1}^{n_y} \mu_B(u_i) - a_i \sum_{i=1}^{n_y} u_i \mu_B(u_i) / [\sum_{i=1}^{n_y} \mu_B(u_i)]^2$ 。

同样对描述输入的词, 若取其隶属度函数为高斯形函数  $s_i^j = \exp[-(x - c_{ij}^2)/\delta_{ij}^2]$ , 则可由  $dE/dc_{ij}$  得到  $s_i^j$  的参数  $c_{ij}$  的调节公式:

$$c_{ij}^{new} = c_{ij}^{old} + h \times dE/dc_{ij}$$

其中： $dE/dc_{ij} = dE/ds_i^j \times ds_i^j/dc_{ij} = \sum_l dE/da_l \times da_l/ds_i^j \times s_i^j \times 2(x - c_{ij}/\sigma_{ij}^2)$ （ $l$ 是所有含有规则的标号）； $da_l/ds_i^j = a_l/s_i^j$ 。

也可以由  $dE/d\sigma_{ij}$  得到  $s_i^j$  的参数  $\sigma_{ij}$  的调节公式：

$$\sigma_{ij}^{new} = \sigma_{ij}^{old} + h \times dE/d\sigma_{ij};$$

其中：

$$dE/d\sigma_{ij} = dE/ds_i^j \times ds_i^j/d\sigma_{ij}$$

也就是  $dE/d\sigma_{ij} = \sum_l dE/da_l \times da_l/ds_i^j \times s_i^j \times 2(x - c_{ij})^2/\sigma_{ij}^3$ ；（ $l$ 是所有含有  $s_i^j$  的规则标号）；其中  $da_l/ds_i^j$ ， $dE/da_l$  同上。

总之，通过式 (17.3) 不断优化神经网络各参数，我们相应地也优化了对应的模糊系统。下面首先通过一个倒立摆的仿真例子来说明这里介绍的神经模糊系统在已给定模糊推理系统时的性能及其优化。

倒立摆系统的示意图如图 17.3：




图 17.3 倒立摆系统的示意图

它的微分描述是以下公式：

$$\ddot{\theta} = \frac{g \times \sin \theta + \cos \theta \times (-F - m \times l \times \dot{\theta} \times \sin \theta)}{l \times (4/3) - m \times \cos^2 \theta / (m_c + m)}$$

其中为长杆相对垂直的偏转角，重力加速度  $g = 9.8\text{m/s}^2$ ，小车的质量  $m_c = 1.0\text{kg}$ ，杆的质量  $m = 0.1\text{kg}$ ，杆的半长  $l = 0.5\text{m}$ ， $F$  是我们作用在小车上的力。仿真的目的是根据输入长杆相对垂直的偏转角  $\theta$ ，和长杆的角速度  $\dot{\theta}$ ，求得恰当的输出  $F$ ，使得在初始条件  $\theta = 20$ ， $\dot{\theta} = 0$  下，尽快让长杆保持平衡。

首先，基于经验可以获得以下 9 条规则：

- 规则 1：IF s1 is PO and s2 is PO THEN u is PL
- 规则 2：IF s1 is PO and s2 is ZE THEN u is PM
- 规则 3：IF s1 is PO and s2 is NE THEN u is ZE
- 规则 4：IF s1 is ZE and s2 is PO THEN u is PS
- 规则 5：IF s1 is ZE and s2 is ZE THEN u is ZE
- 规则 6：IF s1 is ZE and s2 is NE THEN u is NS


规则 7: IF s1 is NE and s2 is PO THEN u is ZE

规则 8: IF s1 is NE and s2 is ZE THEN u is NM


规则 9: IF s1 is NE and s2 is NE THEN u is NL

其中:  $s_1 = \theta, s_2 = \dot{\theta}, u = F$ ; PO = 正, ZE = 零, NE = 负, PL = 正大, PM = 正中, PS = 正小, NL = 负大, NM = 负中, NS = 负小。

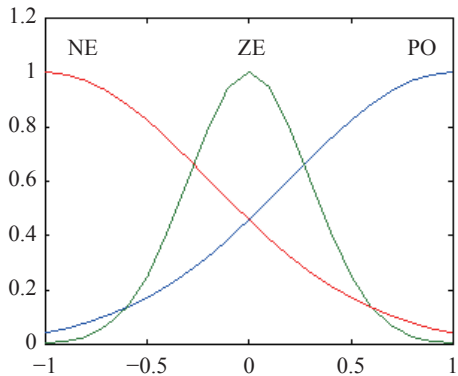
基于经验设置描述输入输出的每个的词隶属度函数 [如图 17.4 的 (a1) (a2) 和图 17.5 的 (a) 所示], 得到的模糊系统输出调节倒立摆已能使其稳定 [参见图 17.6 的 (b) 部分]。但经过历史数据的学习优化相应神经网络系统后, 从神经网络系统恢复出的新模糊系统能够使倒立摆更快地获得稳定 [比较图 17.6 的 (a) 和 (b) 部分]。新神经模糊系统的规则库和推理形式和原来的系统一致, 只是语言变量隶属度函数通过相应的神经网络学习发生了变化 [参见图 17.4 的 (b1) (b2) 和图 17.5 的 (b) 部分]。




(a1) 原始的描述s1的语言变量的隶属度函数



(b1) 训练后描述s1的语言变量的隶属度函数



(a2) 原始的描述s2的语言变量的隶属度函数



(b2) 训练后描述s2的语言变量的隶属度函数

图 17.4 训练前后的描述输入的词之隶属度函数的比较

值得特别指出的是图 17.5 的 (b) 部分中, 关于语言变量 ZE 的隶属度函数有三个。它们对应着规则 3, 规则 5 和规则 7 的结论中的 ZE。这就是说在不同规则中的相同的词可能有不同的隶属度函数形式。

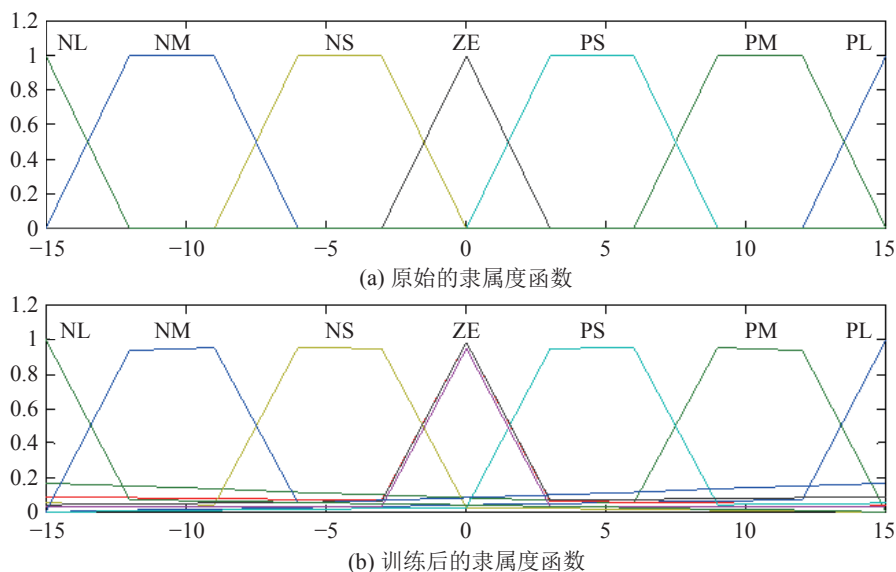


图 17.5 训练前后的描述输出的词之隶属度函数的比较




图 17.6 训练前后的系统表现的比较

### 17.2.2.3 基于神经模糊系统实现“当地简单远程复杂”的控制

更多基于神经模糊系统和基于其的智能控制可以在文献<sup>[2-5]</sup>中找到。正如文献<sup>[4]</sup>所论述的，绝大部分基于神经模糊系统的控制都是将模糊系统转化为易学习的模糊神经网络，然后以这个网络为基础，应用各种已经提出的神经网络控制方式，如神经网络直接逆控制、神经网络自适应控制、神经网络预测控制，等等。

这里我们介绍另外一个将神经模糊系统用于控制的优点，也就是可以利用它来实现“当地简单，远程复杂”的控制<sup>[2]</sup>。这种控制对本地的控制器要求低，可以充分利用远程或者云端的计算能力，可以被视作平行控制的一个简单雏形。具体地说，基于“当地简单远程复杂”控制原理的控制框架是将神经模糊系统中的模糊推理部分放到本地用于控制，而将一一对应的神经网络系统置于远程用于学习优化，其学习算法将借鉴广泛使用的神经网络



络自适应控制方法。

神经网络自适应控制的基本框图如图 17.7(a) 所示。神经网络控制器以当前控制对象的当前状态下  $X(s)$  为输入，给出当前控制量  $u(s)$ ；在  $u(s)$  的作用下，控制对象状态由  $X(s)$  转变为  $X(s+1)$ 。而神经网络控制器以系统经过  $k$  步控制后的实际状态  $X(k+1)$  和目标状态  $X_d(k+1)$  之间的误差值来学习调整各个参数。注意的是，图 17.7(a) 中控制器的训练和执行都在一处，由那个神经网络完成。而在图 17.7(b)，我们列出了新的控制框架，其中控制器的训练和执行部分分别在远程和本地。其中本地执行部分是一个模糊系统，它的参数在由远程的一一对应的神经网络系统设置后，能够从当前状态  $X(s)$  经模糊推理给出  $u(s)$ 。由于模糊推理实现简单，且有便宜和功能强大的模糊推理芯片支持，所以本地的控制器可以低成本实现。远程的训练部分包含与本地模糊系统一一对应的神经网络系统，它同神经网络自适应控制一样，通过然后由系统  $k$  步控制后的状态  $X(k+1)$  和目标状态  $X_d(k+1)$  的误差值来对神经网络的各个参数进行调整（调整算法参考下一节）。调整完后，利用它与本地模糊系统的一一对应性，将参数下载到本地的模糊系统，调整模糊推理系统。

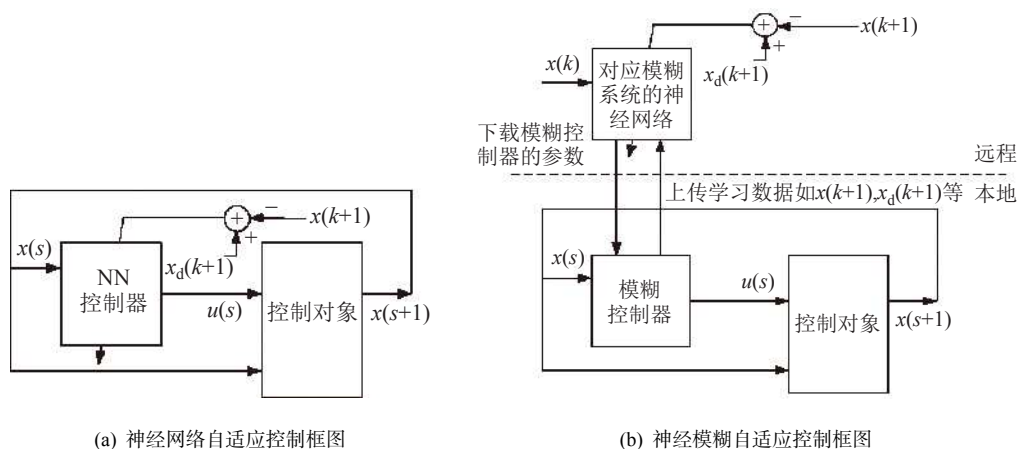


图 17.7 两种自适应控制框图

由上面的描述，不难看出实现远程复杂当地简单控制的关键是有一个包含一一对应的模糊系统和神经网络的神经模糊系统。而这正是前面介绍的神经模糊系统。

在神经模糊系统的输入输出映射确定以后，不妨简记为  $u = NFS(x)$ ，其中  $NFS$  是输入输出映射。如果训练数据是输入和对应输入下的理想控制输出  $u_d$ ，则可以迅速以最小化  $E = (u_d - u)^2/2$  为目的进行基于梯度下降法的参数优化。神经模糊系统中的参数  $W$  的调节公式是：

$$W_{new} = W_{old} + h \times dE/dW = W_{old} + h \times (u_d - u) \times dNFS/dW$$

其中， $h$  是一个小常数， $dNFS/dW$  是神经模糊系统输入输出映射函数式关于参数  $W$  的导数，他们的求法在前面参数训练部分有详细讨论。

但是大多数情况是如图 17.7 所示，控制的目标是在  $k$  步后被控对象达到期望状态  $X_d(k+1)$ 。所以，希望从系统实际状态  $X(k+1)$  和期望状态  $X_d(k+1)$  之间的误差来学习优

化参数。这时有两种情况：

第一种情况，了解被控对象的精确模型  $X(k+1) = M[X(k), u]$ 。这样，最小化误差  $E = [X_d(k+1) - X(k+1)]^2/2$ ，就是最小化  $[X_d(k+1) - M(X(k), u)]^2/2$ ，也就是最小化  $(X_d(k+1) - M\{X(k), NFS[X(k)]\})^2/2$ 。这可以用递归的基于梯度下降法来优化  $NFS$  中的参数。实际上对于  $NFS$  中的参数  $W$ ，有关于它的梯度调整：

$$W(t+1) = W(t) - \eta dE/dW = W(t) - \eta [X_d(k+1) - X(k+1)] \times dX(k+1)/dW$$

其中， $\eta$  是一个小常数， $dX(k+1)/dW$  有如下递归学习公式：

$$dX(k+1)/dW = dM/dX \times dX(k)/dW + dM/du \times dNFS/dW|_{X=X(k), u=u(k)},$$

$$dX(0)/dW = 0$$

其中， $dM/dX$  和  $dM/du$  在被控对象模型  $M$  确定后是可计算的，而  $dNFS/dW$  表示神经模糊系统输入输出映射函数式 17.1 关于  $W$  的导数，也是可计算的。所以可以通过递归学习公式推出  $dX(k+1)/dW$ ，从而得到  $W$  的梯度调整。

第二种情况，对被控对象确实模型  $X(k+1) = M[X(k), u]$  不了解，则可以利用本书系统辨识相关章节使用的方法，构造一个神经网络来模拟模型  $M$ 。这样依然可以使用基于梯度下降的方法优化参数。

下面再次通过倒立摆控制的例子来说明本节提出的基于模糊神经系统的当地简单远程复杂的控制原理实现。

倒立摆系统和针对其的模糊推理系统如前所叙。综合起来，这个系统的可调参数达到 111 个。显然，由计算能力有限的本地控制器对所有这些参数进行学习优化几乎是不可能的。所以，采用基于模糊神经系统的当地简单远程复杂控制。控制框架如图 17.8 所示。

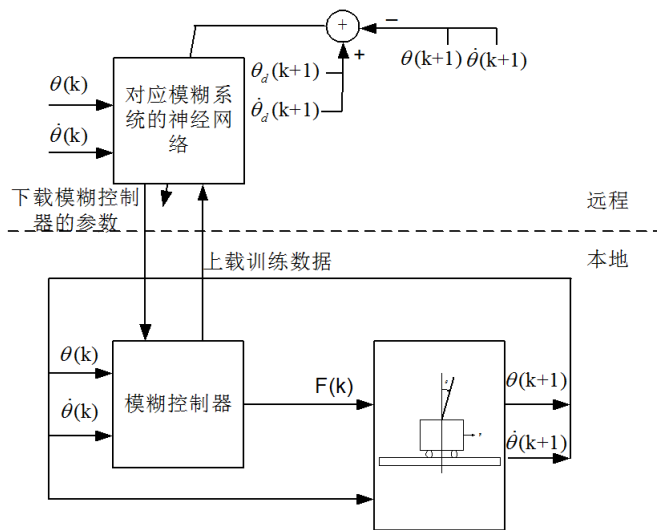


图 17.8 倒立摆系统的当地简单远程复杂控制

初始时，基于经验设置描述输入输出的每个变量的隶属度函数如图 17.4(a1)(a2)，和图 17.5(a) 所示。此时通过这个初始的模糊推理系统得到的输出调节系统已经能使系统稳定，图 17.6(a) 显示了初始条件  $\theta = 20$  度， $\dot{\theta} = 0$  度/秒下应用初始设置的模糊推理系统控制倒立摆的结果。在不同的初始条件下控制倒立摆，可以获得很多经验数据。由于是基于模糊神经系统的当地简单远程复杂控制，可以将一天内的多次通过模糊推理系统控制积累的经验数据上传到远程的复杂学习系统（此处是与模糊推理系统一一对应的神经网络系统）。远程的学习和自适应系统通过学习上传的一天的经验数据，以期望获得更好的控制性能。学习完成后将下载优化后的控制参数代入到当地简单的模糊推理系统。由于神经模糊系统的一一对应特点，当地可以迅速从控制参数恢复出一个优化了的模糊推理系统。经过优化的模糊推理系统也期望可获得更好的控制性能。

上面用一天的经验数据来训练远程的复杂学习系统（神经网络系统）体现了基于神经模糊系统的当地简单远程复杂控制的一个优点：学习时间的任意性。也就是说当地的系统完全可以在模糊推理系统的控制下正常运行，但是由于远程学习系统的存在，可以在任何时候（瞬时或者积累一天甚至一个月的经验数据后）上传经验数据到远程学习系统。同样的，远程的学习系统也可以在任何时候进行学习（接受到经验数据后马上或者积累一天甚至一个月的经验数据后再进行学习优化），以获得优化后的控制参数后下载到当地的基于模糊推理系统的控制器。

下面看一个具体的例子。倒立摆系统每进行一次控制试验后就将获的经验数据上传到远程的学习部分。而学习部分进行学习时，倒立摆系统在原来的模糊推理系统下进行控制。学习完成后，下载学习后的参数，在本地恢复出新的模糊推理系统。然后在新的模糊推理系统的控制下，进行一次试验。试验后再上传经验数据，如此反复 50 次。另外，设定每次试验时倒立摆系统的初始状态都是  $\theta = 20$  度， $\dot{\theta} = 0$  度/秒，控制的目标是经过 100 个周期（每周期为 1/20 秒）的控制后，倒立摆达到稳定： $\theta = 0$  度， $\dot{\theta} = 0$  度/秒。

图 17.9 显示了 50 次学习期间，100 个周期控制后系统状态同目标状态之间误差的变化。图 17.10 显示了 50 次学习期间，系统状态接近目标状态（系统状态同目标状态之间

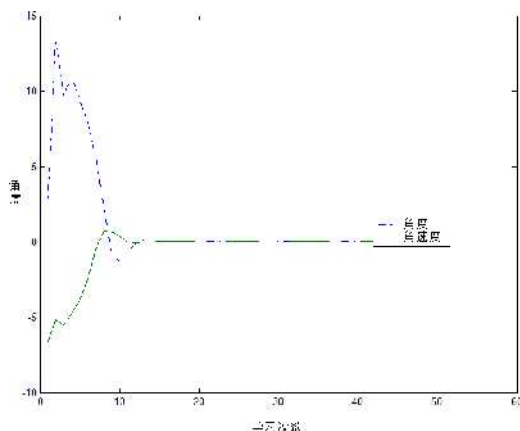


图 17.9 50 次学习训练中 100 个周期控制后系统状态同目标状态之间误差变化





图 17.10 50 次学习训练中系统状态接近目标状态时已经经过的最小控制周期的变化

的均方误差小于 1) 时已经经过的最小控制周期的变化。通过图 17.9 和图 17.10 可以清楚的看见学习对倒立摆系统的影响。在学习的初期, 学习甚至可以导致系统的性能恶化。这时, 当地简单的控制器可以恢复采用原来的模糊推理系统进行控制。但是经过 10 次左右的学习以后, 系统性能就开始迅速优化, 当地简单控制器就可以采用优化的模糊推理系统进行控制。

图 17.11, 显示了 50 次经验数据学习前后的模糊推理系统控制初始条件  $\theta = 0$  度,  $\dot{\theta} = 0$  度/秒下的倒立摆的情况。很明显, 倒立摆在 50 次的经验数据学习后更快的达到稳定。由前一节, 经过 50 次经验数据学习后的规则库和推理形式和学习前的系统一致, 但是学习前后的语言变量隶属度函数分别如图 17.12 和图 17.13 所示。



(a) 学习前模糊推理系统控制性能

(b) 学习后模糊推理系统控制性能

图 17.11 学习前后系统性能比较

这里仍需特别指出的是, 图 17.13(b) 中, 关于语言变量 ZE 的隶属度函数有三个。它们对应着规则 3, 规则 5 和规则 7 中 3 个不同规则的结论中的 ZE。也就是前面提到过的在不同规则中的同样的词可能有不同的隶属度函数形式。

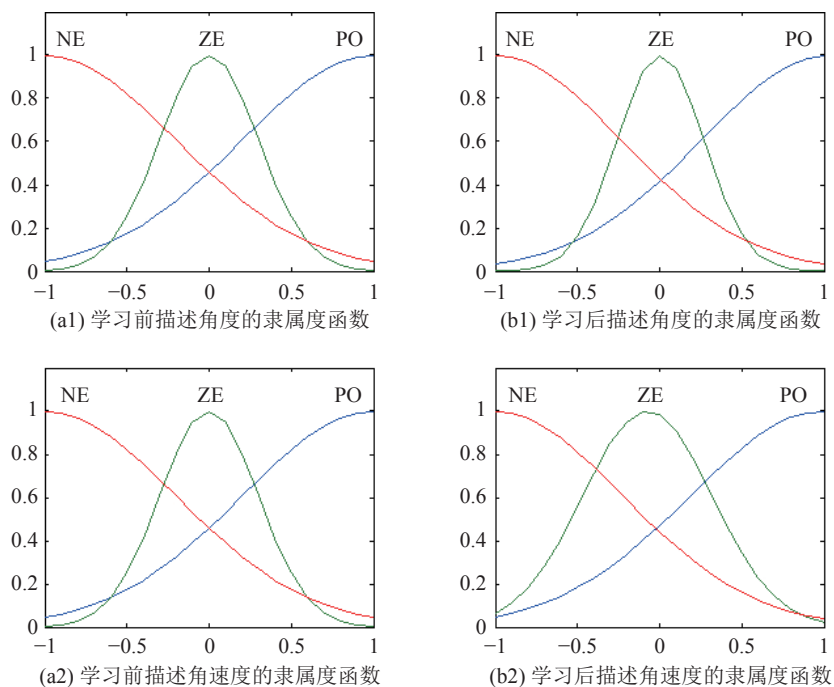


图 17.12 学习前后描述输入的隶属度函数的比较

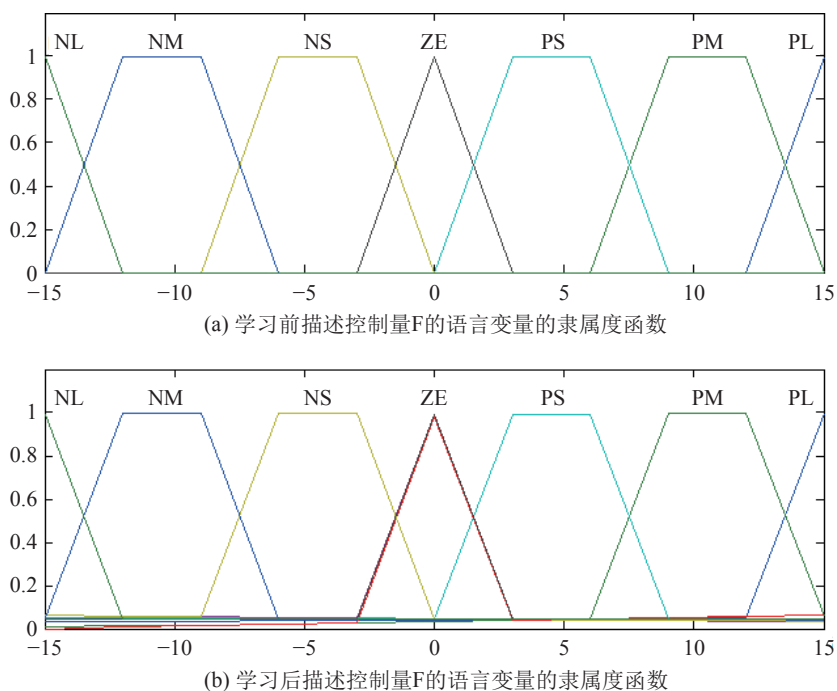


图 17.13 学习前后描述输出的隶属度函数的比较

#### 17.2.2.4 遗传算法优化神经模糊控制器

我们在前面提出的神经模糊系统及其在当地简单远程复杂控制上的应用，充分体现了模糊系统和神经网络这两种智能技术的混合控制可以带来的优势。但是在对此系统中

的神经网络进行优化时，我们采用了基于梯度下降的方法。这种方法尽管表现不错，但是其缺点也是非常明显的。最突出的问题是，梯度下降方法只对连续可导函数有效。而在设计神经模糊系统时，系统专家定义语言变量的隶属度函数时，往往倾向于使用简单易懂的三角形隶属度函数，这个函数并不是处处可导，导致了使用梯度下降方法不太容易。另外一个梯度下降方法的缺点是其容易陷入局部最优，从而影响控制器的性能。这时，我们可以考虑其他的优化方法，如遗传算法和模拟退火算法。当然这些优化算法常常需要更多的计算资源，需要强大的计算能力支持。这个时候，前面介绍的一一对应的神经模糊系统和基于它的远程复杂当地简单的控制方式就体现出优势了。我们可以在非优化期间，直接使用基于模糊推理的控制器。而在优化期间，远程优化与模糊系统一一对应的神经网络控制器。

具体地说，如果我们要用遗传算法优化前面介绍的神经模糊控制器，我们要定义好如下几个关键内容：

(1) 将待优化的神经模糊系统用一个实数序列表示。以前小节列出的倒立摆问题为例，我们可以定义一个实数序列如下，表示一个神经模糊系统：

$$[\sigma_{11}, \sigma_{12}, \sigma_{13}, \sigma_{21}, \sigma_{22}, \sigma_{23}, w_1, w_2, w_3, w_4, w_5, w_6, w_7]$$

这里  $[\sigma_{11}, \sigma_{12}, \sigma_{13}]$  是神经模糊系统第一个输入的三个隶属度函数的参数， $[\sigma_{21}, \sigma_{22}, \sigma_{23}]$  是神经模糊系统第二个输入的三个隶属度函数的参数。最后  $[w_1, w_2, w_3, w_4, w_5, w_6, w_7]$  是系统输出的 7 个隶属度函数的参数。

(2) 定义好每个实数序列（即神经模糊系统）对应的适应度。根据我们神经模糊系统优化的目标  $E = [X_d(k+1) - X(k+1)]^2/2$ ，也就是  $K+1$  步后系统到达期望的状态。我们可以定义适应度为  $1/(E+1)$ 。因为遗传算法重视寻求最大的适应度，我们定义  $1/(E+1)$  为适应度可以保证遗传算法实际是在寻找最小的  $E$ 。

在定义好解的表示和适应度设计，我们就可以利用一般的遗传算法流程来对解进行优化。关于遗传算法的基本流程，本书相关章节已有介绍，这里不再赘述。

### 17.2.3 其他混合计算智能技术的控制

毫无疑问，基于前面对各种计算智能技术的优缺点的分析，我们可以发现其他混合计算智能的方式来应用到控制问题。比如说，我们可以直接利用进化算法来优化模糊系统<sup>[6]</sup>，从而有进化模糊系统控制<sup>[7]</sup>。我们也可以利用进化算法来优化神经网络系统从而有进化神经网络控制<sup>[8,9]</sup>。组合概率推理，学习系统到神经网络，模糊系统，甚至融合进化算法都是可行的方向<sup>[10,11]</sup>。总之，混合计算智能技术的控制期望充分利用混合系统中每种技术的优点，同时利用各技术的互补性来弥补系统的缺点。

## 17.3 人机混合的智能控制

读者可能已经注意到，本书的其他部分只讨论机器、算法、控制系统等客观对象，并未将“人”这个因素加入讨论中来。与本书其他部分不同，本节将讨论在智能控制中加入人的因素后的新型控制系统形式，即“人机混合的智能控制”。将首先讨论人机混合的

智能控制的基本概念,进而探讨两种人机混合的控制形式,即“人在回路控制”和“人机协同控制”。通过本节的学习,希望读者能够理解在智能控制系统中考虑人的因素的必要性,认识到人机混合是一个重要的技术发展趋势,并对两种人机混合的控制形式有初步了解。

让我们先来思考和回顾控制系统、机器和人的基本概念,由此引出本节的正式讨论。

### 17.3.1 控制系统、机器和人

通过本书前面部分的学习,读者对控制系统应该已经有了清晰的概念。通俗来讲,一个控制系统往往通过某种控制手段使得动态系统对象的运行符合某既定要求。控制系统有三个关键组成部分:

(1) 控制的目标,比如稳定性、瞬态性能、其他各种优化指标等,任何控制系统总会有一定的目标要求,系统的运行应该满足这些给定的控制目标;

(2) 控制的方法,这包括控制系统的结构、控制的算法、控制的策略等,这是从事控制理论研究和控制工程设计的人所关注的核心点;

(3) 控制系统的物理构成,主要包含三个不同功能的组件,即,负责感知/测量系统运行状态或输出信息的传感器,负责运行控制算法的控制器,和负责实施控制策略的执行器,另外还有负责连接这些组件的通信链路等辅助组件,这是控制系统的外在形态。

控制系统物理构成的三个组件一般由各种各样的机器来充当。所谓“机器”,广义上是通过变换或传递能量、质量和信息,执行机械运动等达到特定目的的工具、装置或设备的总称。机器包括了种类繁多的温湿度、速度、体积、高度等各种物理量的测量器件,可以测量受控对象的状态/输出信息,从而充当控制系统的传感器;机器也包括了各种从嵌入式到大型的计算设备,可以进行控制算法的运行,从而充当控制系统的控制器;机器也当然包括了机械手、汽车油门、各种开关等执行部件,可以实施制订好的控制策略,从而充当控制系统的执行器。

人在控制系统中的作用,则一方面是控制系统目标的终极来源,因为任何系统的设计总是为人服务的,人是控制系统存在的原因,为控制系统设定目标,赋予价值。这一作用是机器所不具备的。另一方面,人也具有充当控制系统任意组件的能力。事实上,人的各种感觉器官如眼、鼻、舌、皮肤等具有感知各种相关物理量的能力,从而可以充当控制系统的传感器;人的大脑具有独特的智能,可以胜任控制系统的控制器;人的手、脚等也具有活动能力,也从而可以充当控制系统的执行器。

上面的讨论总结归纳为图 17.14。从中可以看出,机器和人都可以充当控制系统的构成组件,而人更可以设定控制的目标。

很容易注意到,在现实中控制系统的物理构成往往仅包含各式各样的机器,并不包含人。如工厂里生产各种产品的自动流水线,中央空调的温度控制系统,自行火炮的射击过程,等等。在这些控制系统中,即便有人参与,往往不过是设定系统的控制目标,一旦目标确定,人便无需存在于控制系统的闭环中了。这意味着一般的控制系统并不需要人的密切参与。自然,人从控制系统中抽身而出符合技术发展的本意:只要有可能,控制系统应当全自动的完成所有任务,而不要求人的事必躬亲。



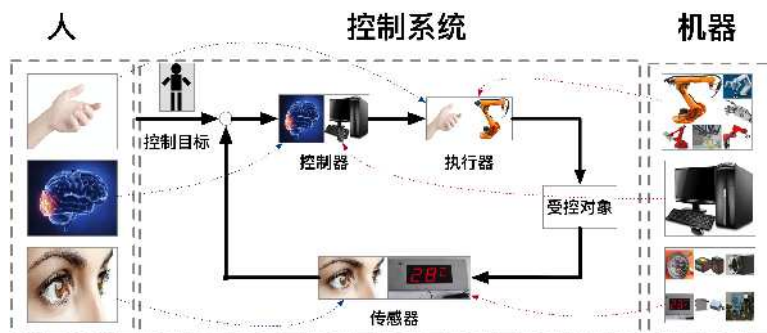


图 17.14 控制系统、机器和人的关系图解

控制系统的目标往往由人来给出，而控制系统的三个组件，即传感器、控制器和执行器，都既可由机器充当，也可由人充当

但是，人是不是真的可以从所有类型的控制系统中抽身而出呢？让我们先来思索如下的两个疑问，这两个疑问启发了我们后续的讨论。

#### 疑问 17.1 人的需求是否总可以离线设计？

绝大多数控制系统都是事先确定好人的需求（反映为控制目标）后再进行系统设计，也即，人的需求在控制系统设计中是“离线”的。这种人的需求的离线设计对固定的或可以事先预测的需求自然不会有问题，比如温度控制，告知空调系统要设定的温度后，人便无需存在于温度控制系统中。但如果人的需求是持续变化不可预知的，将人的需求离线设计是否还可行呢？在这种情况下是否必须将人的因素显式的考虑在控制系统中呢？

#### 疑问 17.2 人的加入是否可以超越单纯机器构成的控制系统？

假如单纯机器构成的控制系统的综合性能永远优于有人参与的，我们当然乐于让机器代劳所有的工作，但如果有一些场景下，人的某些特殊能力是任何机器都难以达到的，是否可以考虑将人的因素考虑进来，设计人机混合的更优的控制系统呢？

上述两个疑问启发了我们在 17.3.3 和 17.3.4 中对两种人机混合的控制形式的讨论。在此之前，让我们先从人机混合的基础概念谈起。

### 17.3.2 人机混合智能控制基本概念

#### 17.3.2.1 人机混合智能控制的必要性

是不是至少对某些特定类型的控制系统，人的因素需要明确、显式的加以考虑呢？让我们从几个例子出发开始讨论。

#### 例 17.1 霍金的高科技轮椅

在他本人的传奇人生外，物理学家霍金所使用的高科技轮椅也为人津津乐道。见图 17.15(a)。根据霍金个人网站上的介绍<sup>[12]</sup>，他的轮椅 1997 年起由英特尔提供。轮椅前部有一台搭载了主控软件 ACAT 的平板电脑。霍金所佩戴的眼镜可使用红外线感应他的面部移动，这产生了一个开关切换信号，该信号进一步用来控制字符输入并进行其他操控。





(a) 霍金的高科技轮椅

(b) 智能弹射座舱

图 17.15 人机混合的智能控制的例子

这是霍金与轮椅的唯一交互手段。ACAT 装载了由 SwiftKey 提供的文字输入预测算法，该算法通过霍金本人的各类出版物进行了适应性训练，能够准确地预测霍金的输入。

容易看出，在霍金轮椅的设计和使用过程中，我们很难将霍金本人的作用从中分离出来：SwiftKey 的预测算法要以霍金先前的出版作品为训练数据，也要不断根据新的数据做调整；面颊移动的识别要针对霍金的具体情况做优化，使用过程中也需要根据具体情况做调整。在霍金的高科技轮椅这个例子上，人是一个不得不密切关注和考虑的显式因素。

### 例 17.2 智能座舱何时弹射？

新式战机往往都安装了一套操控座舱弹射的智能系统，该系统可以自动分析战机飞行状态和飞行员个人信息，保障飞行员在必要时以最大的安全性通过弹射安全逃离座舱，见图 17.15(b)。

现有智能座舱弹射的触发条件是基于人的判断的，也即，需要飞行员拉动弹射手柄弹射过程才会启动。然而，激烈空战很有可能会造成飞行员失去触发弹射的行动能力或直接丧失意识，此时如果有一套不经由飞行员而可以自行触发弹射的机制将极大地提高飞行员的生还率。

这一自行触发弹射机制的成功依赖于机器准确识别人的状态，并在机器控制和人类控制之间做高效切换。在人意识清醒具有行动能力时错误弹射，将造成战机损失；在人丧失触发弹射能力时不能自行触发弹射，则起不到应有保护作用。该系统的设计要求必须将人和机器有机融合在一起，将人的因素做显式的考虑。

### 例 17.3 武器的人类控制

武器系统的“自主性”即武器系统在缺少人为干预的情况下自主选择（搜索、探测、识别、追踪或选择）和攻击（使用武力打击、压制、破坏或摧毁）目标的能力，藉由近些年来迅猛发展的人工智能的介入，俄军方研发的 Kalashnikov 的“神经网络”（Neural Net）系统、以色列的“Harpy”反雷达无人机、韩国的“哨兵机枪”（Super aEgis II Sentry gun），都

是一些具有变革性的新型自主武器系统。显然，任何武器系统的最终控制一定在人的手上，比如，智能导弹飞出后也还需要保留人改变攻击目标的能力<sup>[13]</sup>。但基于人工智能技术的武器系统自主性的快速提高使得武器的人类控制变得越来越困难，致命自主武器系统的失控风险已经成为一个广受关注的议题，国际红十字会曾为此专门召开若干会议进行研讨<sup>[14]</sup>。

为了确保武器的人类控制，必须考虑武器自主性达到的程度及其不确定性，和人参与武器系统控制中的风险和不确定性，这里人的因素也是明确的、显式的。

从上面的例子可以看出，在某些控制系统中若不显式考虑人的因素，或没有人的深度介入，则控制系统就不能达到所设的目标，或者根本不可能（没有人的因素的显式考虑，武器的人类控制就是不可能的），或者效果不好（霍金的轮椅设计如果不全面考虑霍金本人需求，则使用效果必然会打折扣）。因此，在这些控制系统中，加入对人的因素的显式考虑是必要的。

### 17.3.2.2 人机混合智能控制的可能场景和形式

下面列出了若干人机混合的智能控制的典型场景，在其中人的因素必须明确、显式地加以考虑：

（1）人的需求/目标太过复杂或因人、因时而变，无法离线处理：比如各类康复或增强人类身体机能的机器人，其设计和运行要将人的需求显式的纳入控制系统的闭环中；

（2）保持人类控制：比如武器系统尽管自主运行，但人的最终绝对控制是必不可少的，系统设计需要留下人至少可以在关键节点决定系统运行路线的能力；

（3）防止人类出现低级错误或在特定情况下强制接管人类控制的机器设计：比如在智能座舱的例子中机器应该能够准确判断人是否已经丧失触发弹射的能力，并在危急情况下强制触发弹射；

（4）分别利用机器和人的独特优势获得单独一方都无法取得的性能的设计：比如赛博格（Cyborg），或生化人，以机器作为有机体（包括人与其他动物在内）身体的一部分，借由人工科技来增加或强化生物体的能力。

在如上所列的人机混合的智能控制的典型场景中，如果从人在其中所起作用的角度来看，在前二者中人主要是作为控制系统的目的存在，控制系统以满足人的需要为中心，机器起辅助的作用，人在控制系统的回路中；而在后二者中人则与机器处于相同的地位，都是控制系统平等的构成组件，目的是利用各自的优势取得单纯人或机器难以取得的整体效果，设计的要点在于人和机器的有效协同。在这个意义上，前二者是“人在回路控制”，可用于回答疑问 17.1；后二者则可称为“人机协同控制”，可用于回答疑问 17.2。关于这两种特殊控制形式的具体讨论见 17.3.3 和 17.3.4。

当然，人在回路控制与人机协同控制并非截然对立。人在回路控制也往往需要人机的高效协同，人机协同的前提也需要人在回路中。前者主要是从系统结构角度来考虑的，后者则从功能角度来看。作为人机混合的智能控制的两种具体控制形式，二者是紧密联系在一起的，并不能截然分开。

大多数学科或者仅研究人，或者仅研究机器。表 17.2 从与人机混合的智能控制做比较

的角度列出了同时研究人与机器的若干学科领域。读者可以了解到，人机混合的智能控制只是人机混合/融合的一个子领域，而人机交互、人机工程等其他同时研究人与机器的学科领域与人机融合智能控制的关键区别则在于他们并非在智能控制的框架下展开研究的。

表 17.2 同时研究人与机器的学科领域

领域	研究问题和目标	关键特点	例子
人机交互/ 人机界面	人机交互研究系统与用户之间的交互关系；人机界面通常是指用户可见的部分，二者通过设计增强系统的可用性和用户友好性	系统可以是硬件机器或软件，但未必是控制系统；侧重人与机器的交互关系	收音机的播放按键、飞机上的仪表盘、手机界面等的易用性和用户友好性的设计
人机工程 (或人类 工效、人 因工程)	研究人和机器、环境的相互作用及其合理结合，使设计的机器和环境系统适合人的生理及心理等特点，达到在生产中提高效率、安全、健康和舒适的目的	以满足人的需求或人的效能更好发挥为目标，侧重机器和环境设计，而不是人机混合；所研究对象一般也并非控制系统	带有“人体工学”字样的各种产品，如人体工学椅、人体工学键盘等
人在回路	见定义 17.1	人在控制系统回路中起关键的作用	见例 17.4、17.5
人机协同	见定义 17.2	人与机器协作完成单独人或机器无法完成的任务	见例 17.7、17.6

### 17.3.2.3 人机混合与 IoT/CPS、VR/AR、AI、认知科学

人机混合的智能控制在近些年得到了广泛关注，部分得益于物联网（Internet of Things, IoT）和信息物理融合系统（Cyber Physical Systems, CPS）等智能系统的迅猛发展<sup>[15]</sup>。不同于传统的主要面向工业、军事等领域的自动化应用，其中人的因素大多游离于控制系统之外，在典型的物联网和信息网络融合系统实例中（如智能家居产品、可穿戴设备等），人与机器的关系较为密切，系统的设计往往需要密切的关注人的需求。这些智能系统在未来的进一步发展，也预示着人机混合的智能控制的愈加重要。

虚拟现实（Virtual Reality, VR）和增强现实（Augmented Reality, AR）技术的发展也为人机混合的智能控制提供了额外的交互维度，使得人与机器在交互层面上超出了原来的范畴，为新型人机混合形式的出现提供了契机。比如，利用增强现实技术的机器人遥操作，可以更为自然精确地对机器人进行远程控制。

作为最有可能改变未来世界的颠覆性技术，人工智能（Artificial Intelligence, AI）技术的发展则可能为人机混合的智能控制带来了新的模式上的变革。传统的人机混合解决人类控制和机器执行的自动化之间的交互问题，而人工智能技术的发展使得机器也具有了一定的智能自主的能力，从而，传统的仅包含机器自动执行和人类控制的人机系统的两层架构已经不适应新技术的发展，而应该以机器的自动执行、机器的智能自主和人类控制三层架构描述这种新型人机混合的智能控制系统。

要在人机混合的智能控制中将人的不同于其他动物的高级智能考虑进来，则往往离不开认知科学的帮助。认知科学是一门研究信息如何在脑中形成以及转录过程的跨领域学

科，建立在对感知、智能、语言、计算、推理甚至意识等诸多现象的研究和模型化上。要充分理解人在人机混合系统中的作用和影响，将其置于认知科学的框架下研究是自然的选择。

### 17.3.3 人在回路控制

**定义 17.1** 人在回路控制：“人在回路控制”是一种特殊的控制形式，其中人显式的存在于系统闭环回路中且不可简单剥离。

按照定义 17.1，前面的几个例子 17.1、17.2、17.3 中的控制系统都可视为某种人在回路控制系统，因为不管在任何一个例子中，人的作用都是不可简单剥离的。

如前所述，一个控制系统具有（一般由人设定的）控制目标，其物理构成则包含传感器、控制器和执行器等组件。如图 17.14 所示，人在控制系统中既可以行使设定控制目标的功能，又可能充当其中任一物理构成组件。人在控制系统中的可能角色见表 17.3<sup>[6]</sup>。

表 17.3 人在控制系统中的作用

功能	对应控制系统组件	例子
提出需求	控制目标	例 17.1 中轮椅设计要符合霍金的需求
数据获取	传感器	例 17.5 中可穿戴设备获取人的体征信息
执行	执行器	例 17.7 中人对闸门的操控
决策	控制算法/控制器	例 17.3 中人的最终决策

从机器的自主性角度，人与控制系统回路的关系则有三种可能：一是控制系统的操控需要人的具体指令，此时人在闭环中（in-the-loop），人是整个系统中不可缺少的一个部分；二是系统目标由人给出，执行则由具有部分自主性的机器自行进行，此时“人在闭环上”（on-the-loop）；第三则是机器可根据感知信息独立地确定目标并给出具体指令，无需人的介入，此时“人在闭环外”（out-of-the-loop）<sup>[7]</sup>。定义 17.1 主要是从系统结构的角度考虑人在控制系统中的位置，大致包含了上述的“人在闭环中”和“人在闭环上”两种形式。

让我们再来看几个人在回路控制的例子。

#### 例 17.4 智能家居与智能可穿戴设备

在近些年，智能家居设备和系统随着物联网、智能硬件等的迅速发展得到了大面积的普及。智能安防（指纹锁和云端监控等）、智能温控（Nest 温控系统等）、智能灯光（光源联网、情境灯光等）等典型应用场景都有了成熟的产品。相信智能家居产品在未来会得到进一步的发展，使人们的生活越来越智能，越来越方便。但现有的智能家居产品与人的互动依然是极为简单的，在大多数情况下，智能家居产品的使用范式如下：人发出指令，智能家居产品自动执行指令，或者是，智能家居产品监测环境变化，自动执行一定操作。在这两种范式中，人都并不在智能家居系统的闭环回路中。见图 17.16 上半图是现有智能家居系统运行的流程示意。

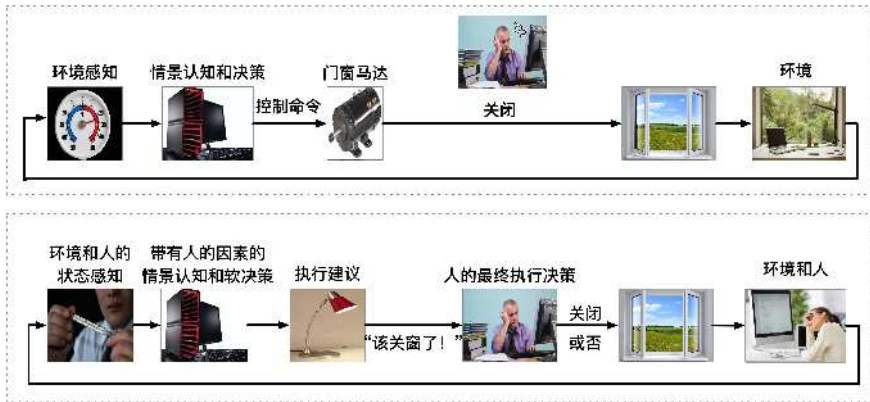


图 17.16 情境感知智能家居（借鉴并重新绘制自文献 [18]）




图 17.17 利用实时心率量测控制自行车骑行（参考文献 [22] 绘制）

智能家居产品是直接为人服务的，其性能的好坏最重要的指标应该是人的主观感受，因此将人显式地置于智能家居系统的闭环中是很必要的。智能家居的人在回路至少在以下两个方面有用：一是利用对人的状态的观测和估计<sup>[19]</sup>，使得智能家居产品的运行可以按照人的状态变化而变，比如随着人的情绪或工作状态而变的灯光系统；二是提供人的最终决断权，智能系统提供执行选项，而由人根据主观意图进行最终选择。这构成为具备情境感知的智能家居的基本框架，见图 17.16 下半图的流程示意。

类似于智能家居产品，智能可穿戴设备近些年也得到了爆发式地增长。大多数智能可穿戴设备本身仅仅是单个的设备，并不构成明显的控制闭环。如手环和智能手表可以测量佩戴者的步数，甚至检测较为复杂的运动形式，或提供在浅睡区叫醒的功能，但在所有这些功能中人的参与并不深入，主要是作为受控对象而存在，并不承担更主动的控制角色。

更广义上讲，各类康复机器人也都属可穿戴设备。比如霍金的轮椅，和用于辅助有困难的人行走的装置等<sup>[20]</sup>。现有的设备在智能化和人的参与上（主要是人的状态估计<sup>[21]</sup>）仍存在比较大的发展空间。

### 例 17.5 人在回路自行车控制

利用可穿戴设备可设计较为复杂的控制系统。在<sup>[22]</sup>中，自行车骑手配备了一个测量心率的穿戴设备，该设备实时进行心率测量，然后与设定心率相比，以此信号调整骑手的骑行功率。系统架构见图 17.17。

数学上，该系统可通过对自行车的车轮角速度  $\omega_p$  的动态变化、人的骑行效率和人的心率动态三者的描述而得到定量刻画。三者的动态系统（状态空间或传递函数）可分别描述如下：

$$\begin{aligned}
 J\dot{\omega}_p &= T_p - D\omega_p + \frac{\tau^2 r_w^2}{\eta} (M_v \dot{\omega}_p + \frac{1}{2} \tau r_w \rho C_x A \omega_p^2 + D_v \omega_p) \\
 &\quad + \frac{\tau r_w}{\eta} [M_v g \sin(\chi_{road}) + M_v g C_r \cos(\chi_{road})] \\
 G_{\tau p}(s) &= \frac{G_\tau + R_{H\omega} (G_{T\omega} G_\tau - G_{\tau\omega} G_T)}{1 + R_{H\omega} G_{\tau\omega}} \\
 \dot{x}(t) &= Ax(t) + Bf(u(t)) \\
 z(t) &= Cx(t) + Df(u(t)) \\
 HR(t) &= HR_0 + \gamma z(t)
 \end{aligned}$$

式中其他参数见 [22]。

在本例中，人的心率、骑行功率等都深入构成为控制系统的一个组成部分，成为一个典型的人在回路的控制系统例子。与单纯机器构成的系统比较，人的心率和骑行功率变化等都具有很大的随意性，因而也就对控制系统的设计提出了不同于传统控制系统的挑战。

人在回路的控制系统大多具有以人为中心、机器是人的辅助的特点<sup>[23]</sup>。智能家居产品的首要目标是满足人对家居生活简单、轻松、自动的要求，可穿戴设备的首要目标是准确监测人的各项状态并提供合理建议，武器的最终控制权在人手中，霍金的轮椅以满足他的需要为唯一存在价值。人加入控制系统的回路中，是因为只有这样人的需求才能得到更好地满足，而不是要辅助机器完成本该由机器完成的功能。

由于上述特点，人在回路控制中最为关键的问题就是对人的需求的准确理解和建模。唯其如此，控制系统的设计才能有的放矢。然而，最为困难的也是难以获取人的准确模型：人的感知、认知、目的、意图、决策等都有太大的随意性和难以量化的特点，很难用控制系统中熟悉的在数学上严格的微分方程、差分方程等工具描述。如何将人的准定量的、可能基于非严格的生理学和心理学模型，与传统控制系统的严格数学模型有机合理的结合起来，是人在回路控制的关键问题。

### 17.3.4 人机协同控制

**定义 17.2** 人机协同控制：

“人机协同控制”是一种特殊的控制形式，通过人和机器在系统内的共同作用，取得单独人或机器无法达到的效果。

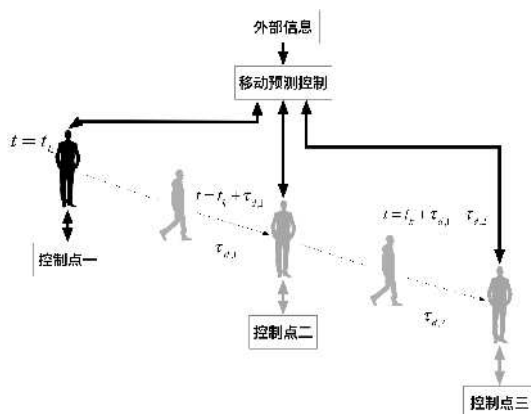
**例 17.6** 机器人外科手术

达·芬奇外科手术系统是一套由人操控机器人进行微创手术的外科手术系统，可用于前列腺切除术、心脏瓣膜修复等手术过程。截至 2012 年该手术机器人已进行了超过 20 万次手术。





(a) 利用达·芬奇外科手术系统进行微创手术



(b) 灌溉渠闸门的人的操作 (参考文献 [25] 绘制)

图 17.18 人机协同控制的例子

在手术过程中，病人躺在特制的手术车中，外科医生则在独立的操作台上通过观看患处 3D 高清视频（经放大），操控手术车上的机械臂进行手术，见图 17.18(a)。

这一系统充分利用了外科医生的医疗知识（知道在何处进行何种操作）和 3D 高清视频系统对患处的放大及机械手在极小尺度下的精确度，达到了单纯人或机器都无法达到的效果：人很难在微创的极小尺度下精确操作，而机器人则难以判断如何进行手术<sup>[24]</sup>。

### 例 17.7 灌溉渠闸门人的操控<sup>[25]</sup>

考虑了一个人在灌溉渠的水位控制中起作用的例子。存在不同层级串联的多个灌溉渠，每个灌溉渠上有闸门可以调节出水量，这些闸门的开关程度必须由人来操作（或者因为闸门的开关没有智能化，或者因为需要保持人类的最终控制），开关程度（也需要由人来报告）决定了下游水位高低。人类操作员比闸门总数少，因此一个操作员需要在若干个闸门间走动并执行控制，系统结构见图 17.18(b)。

灌溉渠  $i$  的水位  $h_i$  的动态变化可由下式刻画：

$$h_i(k+1) = h_i(k) + \frac{T_m}{C_i} [q_{i-1}(k - k_{di}) - q_i(k) + d_i(k)],$$

控制目标是使得灌溉渠水位  $h_i$  接近设定水位  $h_{r,i}$ ，为此，需通过优化如下目标进行模型预测控制：

$$\begin{aligned} \min_{\Delta q_i(k:k+N_c), p_v^j} \sum_{l=0}^{N_p-1} \sum_{i=1}^N \{ & [h_i(k+l) - h_{r,i}]^T Q_i [h_i(k+l) - h_{r,i}] \\ & + Q_{i,i}^T [h_i(k+l) - h_{r,i}] + \Delta q_i^T(k+l) R_i \Delta q_i(k+l) \} \end{aligned}$$

在常规模型预测控制中，求解的只是一串前向的预测控制量；在这里，除了闸门应该进行的操作  $q_i(l)$ （即预测控制量），也包含了每个操作员  $j$  进行操作的最优路径  $p_v^j$ 。这是全然不同于常规模型预测控制的地方。

不同于大多数人机协同控制的例子，在本例中人充当控制系统的传感器和执行器。仍然的，系统仅靠人或者机器无法运行：系统依赖人报告闸门开关和执行操作，但执行何种操作是人自身无法判断决策的，必须由拥有完整信息的中央处理机构运行控制算法才能得出。

尽管在例 17.7 中人可以充当控制系统的传感器和执行器，但在大多数场景下，人最本质的优势还是人特有的智能，这种智能使得人在感知、认知和决策等方面优势突出。因此，人在人机协同中更多承担非执行方面的工作，这种突出人的智能优势的人机协同形成了所谓的“人机融合智能”。在这方面已经有了很多先驱性的工作。例如，依托赛博格的概念，有了脑机融合的混合智能（Cyborg Intelligence）<sup>[26, 27]</sup>。在赛博格中人和机器的功能分野是清楚的：思考决策仅由生物体进行，机器只是增强身体机能。如果我们将机器和生物体的大脑直接相连，即通过设计脑机接口，充分融合人的思考与机器算法、或生物智能和机器智能，以人机混和系统为载体，形成兼具生物智能体的环境感知、记忆、推理、学习能力和机器智能的新型智能，就成了脑机融合的混合智能。另外，从模仿人脑功能的角度出发，也有基于认知计算的混合增强智能<sup>[28]</sup>，定义为模仿人脑功能的新的软硬件，可提高计算机的感知、推理和决策能力。

随着人工智能技术的迅速发展，可能会形成一种新型的自动化/人工智能/人的三层次人机协同框架。在技术发展上，我们已经有了基于控制理论和自动化技术的机器执行层面上物理/机械/电子等的自动化，使得机器具有自动执行具体指令的能力，能够根据给定的指令做出相应的行动。人工智能和大数据等技术则带来了环境感知和策略选择等方面的自主能力，使得机器能够识别周边环境进而自主选择合适策略，发出指令并经由机器的自动化完成最终目标。而人则往往负责最终目标的选择、设定和不确定情况下的临机决断等。这样，就形成了新型的自动化/人工智能/人的三层架构的人机协同控制，该架构见图 17.19。

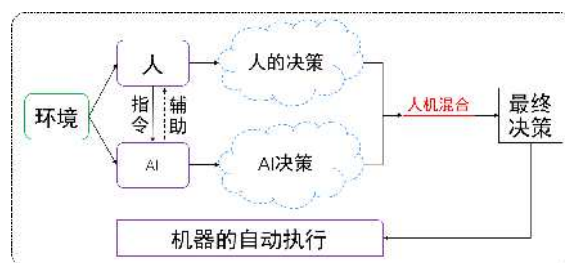


图 17.19 自动化/人工智能/人三层架构人机协同控制

这种将人工智能深度融合其中的人机协同架构的发展面临着巨大的机遇和挑战。首先，以机器学习（深度学习为其典型代表）为基础的人工智能方法基于数据和算法对结果做概率估算，由于方法本身的概率性质和系统的复杂性，结果的不可解释、不可预测是其本质特征，使得其在机器自动化、人类控制之间进行有效融合变得非常困难。其次，机器自动化、人工智能驱动的自主性和人类控制三个不同层面和领域的定量描述程度有显著的差别：自动化领域一般可由严格数学方程描述（如微分/差分方程），人工智能领域一般可由较为严格的计算算法描述但缺少一定的数学精确性，而人类控制则更多依赖规则和直



觉, 缺少量化。如何对这三个领域使用统一可接受的描述语言成为一个基本困难。

尽管有种种困难, 但可以想见的是, 深度融合了人工智能技术的新型人机协同控制架构带来了未来智能控制发展的新范式, 很有可能是未来智能控制发展的一条必由之路。

## 17.4 总结与展望

本章从混合计算智能技术的控制和人机混合的智能控制两个方向讨论了基于混合智能的控制算法。由于现在人们越来越感兴趣将人类或者生物的认知、感知能力加入机器智能中, 从而让机器智能达到甚至超越人类的水平, 混合智能成了当前人工智能的热点。但这需要大量引入神经科学、认知科学、脑科学的研究成果。这种跨学科的融合与合作对智能控制的研究者提出了更高的要求, 但也提供了广阔的研究前景。混合智能的在实现更高层次智能控制的舞台上将大有作为。

## 参考文献

- [1] 陈龙, 王飞跃, 一种新的神经模糊系统及其学习算法 [J], 模式识别与人工智能. 2003, 16(12):178-184.
- [2] 王飞跃, 王成红, 基于网络控制的若干基本问题的思考和分析 [J], 自动化学报, 2002, 28(增刊):171-176.
- [3] J S Jang, C.T Sun. Neuro-fuzzy modeling and control[C]. Proceedings of the IEEE, 1995, 83(3):378-406.
- [4] C T Lin, C G Lee. Neural fuzzy systems[J]. PTR Prentice Hall, 1996.
- [5] F Y Wang, H m Kim. Implementing adaptive fuzzy logic controllers with neural networks: A design paradigm[J]. Journal of Intelligent Fuzzy Systems 1995, 3(2):165-180.
- [6] O Cordon, F Gomide, F Herrera, et al. Ten years of genetic fuzzy systems: current framework and new trends[J]. Fuzzy sets and systems, 2004, 141(1):5-31.
- [7] C L Karr, E J Gentry. Fuzzy control of ph using genetic algorithms[J]. IEEE Transactions on Fuzzy Systems, 1993, 1(1):46.
- [8] C F Juang. A tsf-type recurrent fuzzy network for dynamic systems processing by neural network and genetic algorithms[J]. IEEE Transactions on Fuzzy Systems, 2002, 10(2):155-170.
- [9] M A Lewis, A H Fagg, A Solidum. Genetic programming approach to the construction of a neural network for control of a walking robot, in Robotics and Automation, 1992[J]. 1992 IEEE International Conference on 1992:2618-2623.
- [10] A T Azar, S Vaidyanathan. Computational intelligence applications in modeling and control[J]. Springer, 2015.
- [11] Q Zhu, A T Azar. Complex system modelling and control through intelligent soft computations[J]. Springer, 2015.
- [12] S Hawking. The Computer[Online]. Available: <http://www.hawking.org.uk/the-computer.html>.
- [13] E Suhir. Human-in-the-Loop (HITL): Probabilistic Predictive Modeling (PPM) of an Aerospace Mission/Situation Outcome[J]. Aerospace, 2014, 1(13):101-136.
- [14] 红十字国际委员会. 自主武器系统: 增强武器关键功能的自主性带来的影响 [M]. 韦尔苏瓦. Tech. Rep., 2017.
- [15] D Gorecky, M Schmitt, M Loskyll, et al. Human-Machine-Interaction in the Industry 4.0 Era[J]. 12th IEEE International Conference on Industrial Informatics (INDIN). 2014:289-294.

- [16] D S Sousa Nunes, P Zhang, J Sa Silva. A Survey on Human-in-the-Loop Applications Towards an Internet of All[J]. IEEE Commun. Surv. Tutorials, 2015, 17(2):944-965.
- [17] V Boulanin, M Verbruggen. Mapping the Development of Autonomy in Weapon Systems[M]. 韦尔苏瓦:Tech. Rep., 2017.
- [18] J Domaszewicz, S Lalis, A Pruszkowski, et al. Soft Actuation: Smart Home and Office with Human-in-the-Loop[J]. IEEE Pervasive Comput., 2016, 15(1):48-56.
- [19] K A Tahboub. Intelligent Human-Machine Interaction Based on Dynamic Bayesian Networks Probabilistic Intention Recognition[J]. J. Intell. Robotic Syst., 2006, 45(1):31-52.
- [20] Y Ding, M Kim, S Kuindersma, et al. Human-in-The-Loop Optimization of Hip Assistance with A Soft Exosuit During Walking[J]. Science Robotics, 2018, 3(15):5438.
- [21] M Kim, Y Ding, P Malcolm, et al. Human-in-The-Loop Bayesian Optimization of Wearable Device Parameters[J]. PLoS ONE, 2017, 12(9):1-15.
- [22] M Como, P Giani, M Tanelli, et al. Human-in-the-Loop Bicycle Control via Active Heart Rate Regulation[J]. IEEE Trans. Contr. Syst. Technol., 2015, 23(3):1029-1040.
- [23] G Grote, J Weyer, and N A Stanton. Beyond human-centred automation – concepts for human-machine interaction in multi-layered networks[J]. Ergonomics, 2014, 57(3):289-294.
- [24] M Liu, M Curet. A Review of Training Research and Virtual Reality Simulators for the da Vinci Surgical System[J]. Teach. Learn. Med., 2015, 27(1):12-26.
- [25] P J van Overloop, J M Maestre, A D Sadowska, et al . Human-in-the-Loop Model Predictive Control of an Irrigation Canal[J]. IEEE Control Syst. Mag., 2015, 35(4):19-29.
- [26] Z Wu, Y Zhou, Z Shi, et al. Cyborg Intelligence: Recent Progress and Future Directions[J]. IEEE Intell. Syst., 2016, 31(6):44-50.
- [27] M F Brown, A A Brown. The promise of cyborg intelligence[J]. Learn Behav, 2016, 45(1):5-6.
- [28] N N Zheng, Z Y Liu, P J Ren, et al. Hybrid-augmented intelligence: collaboration and cognition[J]. Frontiers Inf. Technol. Electronic Eng., 2017, 18(2):153-179.

撰稿人：陈 龙 赵云波 陈俊龙