

## 机械臂神经网络变结构控制器

裴海龙 周其节 梁天培  
(华南理工大学自动化系·广州, 510641) (香港理工大学)

**摘要:**本文将变结构原理引入网络控制器的鲁棒性设计。结果表明,此类控制器可自动补偿由于不精确学习或系统参数变化而引起的动态特性上的不足。

**关键词:**变结构控制; 神经网络; 机器人

### 1 引言

机械臂的控制已有许多可行方法,如 PID 控制,逆动力学方法等<sup>[2]</sup>。如果机械臂的参数及负载精确已知,逆动力学方法是十分有效的,理论上它可以保证精确跟踪。然而不确定性因素不可避免地存在于机械臂的运动中。因此研究具有不确定性的机械臂模型的控制问题,在理论和应用上都有重要意义。基于模型的鲁棒控制研究已有不少成果,如变结构控制和自适应控制等,但是在模型未知或模型参数变化较大时,这些方法仍有一定的局限性。

人工神经网络由于其在学习、自适应和联想记忆方面的特殊功能,已引起了人们的广泛兴趣,神经网络控制也已成为目前自动控制领域的一个热门课题,且已有了不少的控制策略和应用实例<sup>[1]</sup>。然而,凡做过网络学习计算仿真的人都或多或少有这样的认识:网络学习一般不是一个很快的收敛过程,特别是当学习达到一定精度后,其收敛的速度变得相当缓慢;尽管神经网络也具有一定的泛化或联想(generalizing)功能,但当被控制系统的参数变化较大时,整个系统动态特性可能完全改变。因此,如何设计具有强鲁棒性的神经网络控制器,并且在保证控制性能前提下具有较少的学习次数,该工作具有重要的实际意义。

### 2 神经网络控制器

考虑未知机器人的动力学系统为

$$\tau = f(\theta, \dot{\theta}, \ddot{\theta}). \quad (1)$$

对于一般机器人轨迹控制系统,如下的 PID 线性反馈控制可满足其轨迹跟踪误差渐近有界<sup>[2]</sup>

$$\begin{aligned} \tau_i &= \alpha_i(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i1}(\theta_{di} - \theta_i) + k_{i2} \int_0^t (\theta_{di} - \theta_i) dt \\ &= \alpha_i S_i(e). \end{aligned} \quad (2)$$

当  $\alpha_i$  足够大时,系统为高增益系统,可保证跟踪误差渐近收敛。这里  $\theta$  为实际的位置向量,  $\theta_d$  为期望的位置向量。通常,选取  $k_i$  使得  $p^2 + k_{i1}p + k_{i2}$  为一 Hurwitz 多项式,即  $S(e) = 0$  为误差的  $e$  的一个稳定曲面。

\* 京港交流中心 [90078/R] 和广东省科学基金 [930012] 资助项目。

本文于 1995 年 1 月 9 日收到, 1995 年 7 月 20 日收到修改稿。

神经网络学习控制系统的设计如图1所示。图中网络的功能在于实现关节位置向量到驱动力矩的映射,即 $\Phi(\theta, \dot{\theta}, \theta, w) = \tau_n$ ,这里 $\Phi, w$ 代表神经网络及其相应的权。此力矩与PID控制器的输出力矩 $\tau_s$ 相加成为整个系统的控制力矩。

$$\tau_n + \tau_s = f(\theta, \dot{\theta}, \theta). \quad (3)$$

而 $\tau_s$ 又反馈回来作为网络的修正误差信号,与[3]中不同, $\theta$ 取为网络的一个输入。为避免计算 $\tau_n$ 时对 $\theta$ 的直接测量,我们取

$$\theta_{oi} = \theta_{di} + k_{i1}(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i2}(\theta_{di} - \theta_i). \quad (4)$$

代替 $\theta_i$ 作为网络的输入。从下面的分析中可以看到,利用这种方法,当PID控制器的输出趋于零时,网络真正完全近似系统的逆动态系统。

假如经过训练后的网络完全等价系统的逆动态系统,即

$$\Phi(\theta, \dot{\theta}, \theta, w^*) = f(\theta, \dot{\theta}, \theta). \quad (5)$$

$w^*$ 表示期望的值。

则由(3)可得

$$\begin{aligned} \tau_n &= \alpha S_i(e_i) \\ &= \alpha[(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i1}(\theta_{di} - \theta_i) + k_{i2} \int_0^t (\theta_{di} - \theta_i) dt] = 0. \end{aligned} \quad (6)$$

对 $S_i$ 微分后可得

$$S_i(e_i) = \dot{\theta}_{di} - \dot{\theta}_i + k_{i1}(\theta_{di} - \theta_i) + k_{i2}(\theta_{di} - \theta_i) = 0. \quad (7)$$

由此推出系统的加速度响应

$$\ddot{\theta}_i = \dot{\theta}_{di} + k_{i1}(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i2}(\theta_{di} - \theta_i). \quad (8)$$

与(4)比较可知,  $\ddot{\theta}_i$ 即为希望的系统响应。

在训练网络时,  $\Phi(\theta_0, \dot{\theta}, \theta, w)$ 与 $f(\theta, \dot{\theta}, \theta)$ 存在的误差可表示为

$$f(\theta, \dot{\theta}, \theta, w) - \Phi(\theta_0, \dot{\theta}, \theta, w) = \alpha S. \quad (9)$$

利用梯度法可得出一种有效的学习规律<sup>[4]</sup>

$$w = -\eta \frac{\partial \Phi}{\partial w} S. \quad (10)$$

其中 $\eta$ 为正常数因子,决定学习的速率。这种方法也就是所谓的误差回传法。文献[5]指出实时学习规律(10)在某种程度上为整个系统的另一个部分反馈,当 $\eta$ 很小时,(10)可训练网络而不破坏整个系统的稳定性,这一点也可从[6]中所谓的慢变化参数理论理解。我们对此也利用奇异摄动方法对整个系统(包括网络)的收敛性作了理论的证明<sup>[9]</sup>,其基本思路为将被控系统考虑为一快系统,网络学习(10)考虑为一慢系统,当 $\eta$ 足够小时,可在保证不影响原系统的稳定性前提下满足网络学习的局部收敛。限于篇幅,这里不作详细推导。

由前面的讨论,完成训练后的神经网络可保证如下两式成立

$$\theta_0(t) = \theta(t), \quad (11)$$

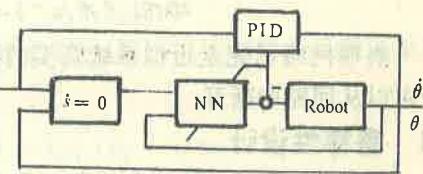


图1 机械臂神经网络控制学习

$$\Phi(\theta_0, \dot{\theta}, \theta, w^*) = \Phi(\theta, \dot{\theta}, \theta, w^*) = f(\dot{\theta}, \ddot{\theta}, \theta). \quad (12)$$

表明网络已完全近似系统真实的逆动态系统. 而此时 PID 控制器的输出保证为零, 完全可以从回路中断开.

### 3 鲁棒性设计

变结构控制系统在具有模型不确定性和外部干扰的情况下已被公认为是一种较好的鲁棒设计方法<sup>[7,8]</sup>. 其基本思想为设计一个滑动曲面  $G$ , 通常为误差(包括模型不确定性及干扰)的一个稳定的微分算子

$$G = G(e).$$

其中

$$e(t) = \theta_d(t) - \theta(t).$$

如果适当选择控制变量, 使得

$$GG < -\gamma |G|, \quad \gamma > 0. \quad (13)$$

则系统将在一个给定的时间

$$t_s \leq \frac{G(e(0))}{\gamma}$$

内达到曲面  $G(t) = 0$ , 并保持在此曲面上滑动, 使得误差趋于零.

根据上节的讨论, 图 1 中训练好的网络控制可以满足被控制系统沿着  $S(e) = 0$  运动, 其响应等价于一个解耦的线性系统

$$\ddot{\theta}_i = \theta_{di} + k_{i1}(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i2}(\theta_{di} - \theta_i). \quad (8')$$

当系统的参数变化时, 例如机械臂的负载增加或减少, 此时系统的动力学方程(1)发生变化, 记为  $f'(\theta, \dot{\theta}, \theta)$ , 方程(11), (12) 不再成立, 因而系统将离开曲面  $S$ , 即  $S(e) \neq 0$ . 此时, 取期望的系统加速度响应(4)为

$$\ddot{\theta}_{0i} = \theta_{di} + k_{i1}(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i2}(\theta_{di} - \theta_i) + r \operatorname{sgn}(S_i). \quad (14)$$

则有

$$\dot{S}_i = \ddot{\theta}_{di} - \ddot{\theta}_i + k_{i1}(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i2}(\theta_{di} - \theta_i)$$

$$= -\gamma \operatorname{sgn}(S_i) + \theta_{0i} - \theta_i$$

$$= -\gamma \operatorname{sgn}(S_i) + f^{-1}(\theta, \dot{\theta}; \tau) - f'^{-1}(\theta, \dot{\theta}, \tau). \quad (15)$$

其中

$$\operatorname{sgn}(x) = \begin{cases} +1, & x > 0, \\ -1, & x < 0. \end{cases} \quad (16)$$

$f^{-1}(\dot{\theta}, \theta, \tau)$  为系统(1)中  $\dot{\theta}$  的隐函数.

$$\text{显然, 若 } \gamma \geq \|f^{-1}(\dot{\theta}, \theta, \tau) - f'^{-1}(\dot{\theta}, \theta, \tau)\|, \quad (17)$$

仍有  $S_i \dot{S}_i < 0$  成立, 即  $\dot{S}$  具有吸引性. 这样, 增加了变结构控制后的网络控制器可保证变化后的系统仍沿着曲面  $S$  运动, 整个变结构神经网络控制系统由图 2 所示.

这里可将本节上述的讨论总结为:

**定理 3.1** 对系统(1)及相应的神经网络控制器(12), 若取控制器(12)的输入

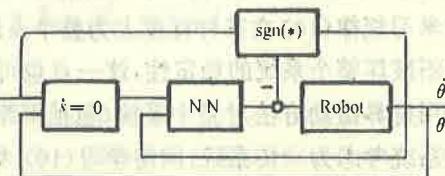


图 2 变结构神经网络控制

$$\dot{\theta}_{01} = \ddot{\theta}_{di} + k_{i1}(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i2}(\theta_{di} - \theta_i) + r \operatorname{sgn}(S_i). \quad (14)$$

其中  $\operatorname{sgn}(\cdot)$  满足(16),  $\gamma$  满足(17), 则当系统(1)参数变化时, 原网络控制器仍可保证系统(1)沿曲面

$$S_i(e_i) = (\dot{\theta}_{di} - \dot{\theta}_i) + k_{i1}(\theta_{di} - \theta_i) + k_{i2} \int_0^t (\theta_{di} - \theta_i) dt$$

滑动.

从另一方面考虑, 若将(17)改为

$$\gamma > \|f^{-1}(\theta, \theta, \Phi(w^*, \cdot)) - f^{-1}(\theta, \theta, \Phi(w, \cdot))\|. \quad (17')$$

则(14)的另一重要意义在于, 只需对原系统的近似学习, 允许存在一定的学习误差, 变结构网络控制仍可满足精确跟踪的要求, 即

**定理 3.2** 对系统(1)及相应的神经网络控制器(12), 若取控制器(12)的输入

$$\dot{\theta}_{01} = \ddot{\theta}_{di} + k_{i1}(\dot{\theta}_{di} - \dot{\theta}_i) + k_{i2}(\theta_{di} - \theta_i) + \gamma \operatorname{sgn}(S_i). \quad (14)$$

其中  $\operatorname{sgn}(\cdot)$  满足(16),  $\gamma$  满足(17'), 则当对控制器(12)的学习存在误差  $\delta = w^* - w$  时, 此网络控制器  $\Phi(w, \cdot)$  仍可保证系统(1)沿曲面

$$S_i(e_i) = (\dot{\theta}_{di} - \dot{\theta}_i) + k_{i1}(\theta_{di} - \theta_i) + k_{i2} \int_0^t (\theta_{di} - \theta_i) dt$$

滑动.

#### 4 对一个两自由度机械臂的仿真

图 3 表示的是一双连杆机械臂, 其详细的动力学方程及参数见[7, 8, 10]. 这里假设除了关节角位移和角速度可以实时测量, 其它关于机械臂的精确模型及参数未知.

多数具有可以近似非线性映射功能的神经网络都可用来自做为控制器, 这里我们采用一个含有两个隐层的前馈网络, 其中第一隐层上有 30 个神经元, 第二隐层上同样也有 30 个神经元. 整个网络有 6 个输入(3 个输入  $\times$  2 个关节), 2 个输出(力矩), 网络权的学习规律为(10), 与[4]中相似, 网络初始的权取为 -1 和 +1 间的随机数.

学习规律(10)为一连续形式, 在实际运算中将其离散化为

$$\Delta w(n+1) = -\eta \frac{\partial S^T(n)}{\partial w} S(n).$$

式中  $n$  表示第  $n$  步. 为了防止发散振荡, 需要取很小的学习速率, 这样会使系统的收敛非常缓慢, 为此, 我们选取

$$w(n+1) = \eta \left( -\frac{\partial S^T(n)}{\partial w} S(n) + \xi_1 \Delta w(n) + \xi_2 \Delta w(n-1) \right).$$

$\xi_1, \xi_2$  的作用在于滤掉网络权空间中的高频偏差, 相应地也可取大  $\eta$  值以增加收敛速率[4]. 这里,  $\xi_1, \xi_2$  的值分别取 0.8 和 0.4.

网络的训练结构图如图 1 所示, 其中 PID 控制器的参数选为

$$k_1 = (9.0, 8.0)^T, \quad k_2 = (20.0, 15.0)^T, \quad \alpha = 100.$$

网络的训练过程是让机械臂跟踪如下的期望轨迹

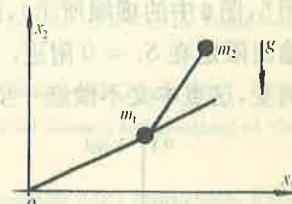


图 3 双连杆机械臂

$$\theta_{d1} = 2\sin(t - \pi/2) + 2, \quad \theta_{d2} = -\sin(1.3t - \pi/2) - 1.$$

为显示整个学习过程, 将往复误差的均方

$$E = \int_0^T [(\theta_{d1} - \theta_1)^2 + (\theta_{d2} - \theta_2)^2] dt$$

与往复次数显示为图 4.

由图 4 显示的结果可知, 经过几个往复后, 误差已收敛到容许的范围, 此时, 机械臂的逆动力学系统已完全由网络近似, 在某种程度上, PID 控制器已失去存在的意义, 可以从回路中断开, 网络控制器可以独立完成系统的控制. 控制结果由图 5, 图 6 中的实线所示, 已具有了较好的精度, 其所产生的较小误差是因为网络仍只是在一定精度内的近似(由图 4 可看到最后仍存在误差). 理论上讲, 只要增加足够次数的往复循环学习, 这种误差是可以消除的<sup>[4]</sup>. 然而, 凡做过网络学习计算仿真的人都有这样的认识, 就是当网络学习已达到某种精度后, 无论采取什么措施, 其后的收敛速度都会变得相当缓慢, 这种耗时的工作在实际设计中显然是不可取的, 完全可以通过上节的鲁棒设计技巧加以避免. 上节描述的鲁棒设计就是一个很好的方法, 将网络的输入变为(14), 其中  $\gamma = 0.1$ . 这时, 网络控制的品质可得到进一步的提高(如图 5, 图 6 中的虚线所示), 图 7 表示的是此时关节 1 的输出力矩. 力矩的连续跳变表明系统的输出限定在  $S_i = 0$  附近. 当然, 变结构理论中常用的边界层方法也可用来减少控制力矩的跳变, 这点本文不做进一步的讨论.

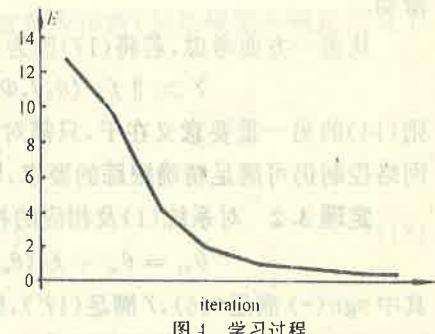


图 4 学习过程

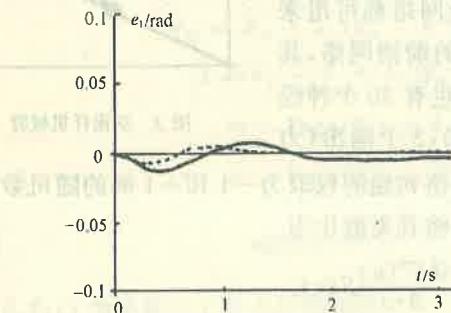


图 5 关节 1 误差

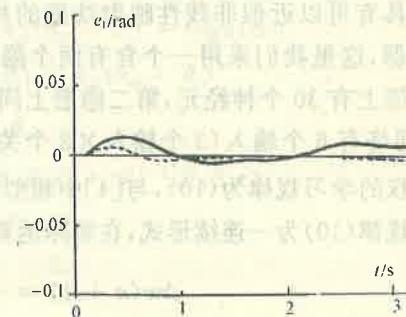


图 6 关节 2 误差

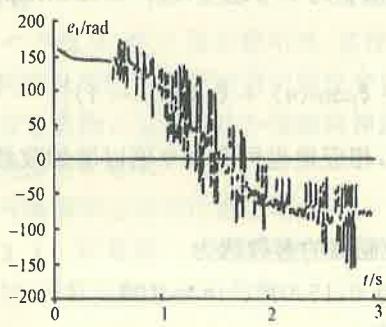


图 7 关节 1 力矩

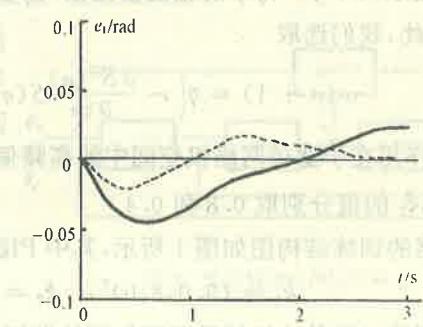


图 8 关节 1 误差

当机械臂的负载从2.5kg增加到5kg后(增加100%),图8、图9表示原网络器的动态特性已受到影  
响(图中实线所示).然而加入了变结构设计后,仍可得到较为满意的结果(图中虚线所示),因而这种控制策略具有较强的鲁棒性.

## 5 小 结

本文讨论神经网络控制器实现机器人的轨迹跟  
踪,主要方法是设计网络学习被控系统的逆动态系

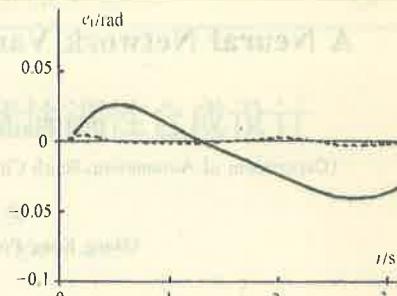


图9 关节2误差

统,以实现一种近似的解耦线性化(如(8)所示).变结构方法的引入,增强了控制器的鲁棒性,其优点主要表现在:①变结构控制的存在,增强了网络的泛化能力.当被控系统参数变化时,需要引进新的样本点训练网络,但对BP算法而言,每一新的样本点都将引起所有权的改变,本文的方法可以避免新的学习而使原网络控制器仍能很好地完成控制任务;②在实际中,网络控制的学习过程最终总或多或少地存在误差,因而影响系统的动态特性,含有变结  
构模式的网络控制器可以自动补偿这些由于不精确学习而引起的动态特性上的不足.因此,与网络的学习精度密切相关的学习次数可降低很多.

## 参 考 文 献

- [1] Antsaklis, P. J., Atherton, D. P. and Warwick, K.. Neural Networks for Control Systems. IEE Control Engineering Series, 46
- [2] Koivo, A. J.. Fundamentals for Control of Robotic Manipulators, New York: John Wiley & Sons, Inc., 1989
- [3] Kawato, M., Furukawa, W. and Suzuki, R.. A Hierarchical Neural-Network Model for Control and Learning of Voluntary Movement. Biol. Cybern., 1987, 57: 169—189
- [4] Rumelhart, D. E., Hinton, G. E. and Williams, R. J.. Learning Internal Representations by Error Propagation. Parallel Distributed Processing: Explorations in the Microstructure of Cognition, D. E. Rumelhart & J. L. McClelland (Eds.) MIT Press, 1986
- [5] Ronald, J. W. and David Zipser. A Learning Algorithm for Continually Running Fully Recurrent Neural Networks. Neural Computation, 1989, 1: 270—280
- [6] Kelman, K.. A Stability Property. IEEE Trans. Automat. Contr., 1986, AC-31: 766—768
- [7] Young, K. D.. Controller Design for a Manipulator Using Theory of Variable Structure Systems. IEEE Trans. Syst., Man, Cybern., 1978, SMC-8: 101—109
- [8] Pei, H. L. and Zhou, Q. J.. Variable Structure Control of Linearizable Systems with Applications to Robot Manipulators. Proceedings of 1991 IEEE International Conference on Robot and Automation, 522—527
- [9] Pei, H. L., Zhou, Q. J. and Leung T. P.. On Learning Convergence of A Kind of Real-Time Neural Network Nonlinear Control Systems. Proc. of the First Chinese World Congress on Intelligent Control and Intelligent Automation, 1993, 601—611
- [10] Leung, T. P., Zhou, Q. J. and Pei, H. L.. A Robust Neural Network Controller. Proc. of 1992 American Control Conference, 1992

## A Neural Network Variable Structure Robot Controller

PEI Hailong and ZHOU Qijie

(Department of Automation, South China University of Technology • Guangzhou, 510641, PRC)

T. P. Leung

(Hong Kong Polytechnic University • Hong Kong)

**Abstract:** In this paper, variable structure control methods are introduced to robustify the neural network controller. Simulation results demonstrate that this scheme can achieve fast and precise robot motion control under the circumstances of load changing and inaccuracy of inverse-dynamics learning.

**Key words:** neural networks; variable structure control; robot

### 本文作者简介

裴海龙 见本刊1996年第1期第10页。

周其节 见本刊1996年第1期第10页。

梁天培 1946年生。1967年毕业于香港大学机械工程系。而后获得香港大学硕士、伦敦大学哲学博士和清华大学工学博士学位。现任香港理工大学副校长兼理学院院长及机械工程系讲座教授。香港工程师学会会长,研究兴趣为自动控制、CAD专家系统、机器人及其控制。

## 中国科学技术大学 GPS 实验室简介

(中国科学技术大学·安徽合肥,230026)

GPS 实验室负责人鲍远律教授 1993 年访问美国 Houston, NASA 宇航中心, 承接了美国 Amchuan (Houston) Inc. 为中国交通部开发的船用 GPS 导航仪项目, 从而带回了制造 24 颗 GPS 导航卫星的 Rockwell 公司的工程技术资料及相应的元器件。作为 Rockwell 公司亚洲中国大陆 GPS 业务总代理的 Amchuan (Houston) Inc. 总裁 Gene Xu 授权鲍远律教授为该公司的 GPS 国内业务全权代理, 随时以最低的代理价并在 6 周供货周期内提供 Rockwell 公司的最新(军用)接收头, 从而保证了 GPS 系列产品的进口件来源。

GPS 实验室的人员以科大的研究生和高材生为主体。目前实验室有来自科大动化系、少年班、软件班、无线电系的三、四、五年级学生共 18 名, 另有硕士研究生 6 名, 博士研究生 1 名。由于充分发挥了科大人才资源的作用, 实验室对高新技术的消化和研制, 包括软件编程的效率是任何公司研究所均难以相比的。

现在固定资产为 486 计算机 4 台, 386 计算机 5 台, 还有 PC/XT, 286, 打印机, 多台仿真器等, 连同 30 台 GPS 样品机及其它元器件总共价值 60 万元人民币(待评估)。目前以开发成功和正在开发的 GPS 产品可分为以下 14 个系统: ①字符微型机; ②汉显手掌机; ③汉字输入输出型便携机; ④海图型船用导航仪; ⑤存储型大地面积测量仪; ⑥通用型位置传感器(带差分 GPS); ⑦省、市地图存储卡型车用 GPS 导航仪及 IC 卡选件; ⑧车辆安全监控系统; ⑨DGPS 车辆精确监控系统; ⑩向量电子地图自动生成平台, 智能监控系统, GPS 与 GIS 混合系统软件; ⑪军用卫星通讯车辆天线位置自动控制板; ⑫笔记本电脑型 GPS 开发平台; ⑬海洋浮标的差分定位与报警; ⑭火车旅程显示安全系统。

(下转第 241 页)