

TR-H-052

中枢神経系における
運動の適応・学習メカニズムモデル
に関する研究

五味 裕章

1994. 2. 3

ATR 人間情報通信研究所

〒619-02 京都府相楽郡精華町光台 2-2 ☎07749-5-1011

ATR Human Information Processing Research Laboratories

2-2, Hikaridai, Seika-cho, Soraku-gun, Kyoto 619-02 Japan

Telephone: +81-7749-5-1011

Facsimile: +81-7749-5-1008

中枢神経系における
運動の適応・学習メカニズムモデル
に関する研究

五味 裕章

The computational mechanisms of adaptive and learning motor control by the central nervous system

Hiroaki Gomi

Abstract

In biological systems such as human beings and monkeys, many kinds of sophisticated limb, finger and eye movements are performed by complex neural processing in the central nervous system (CNS). The purpose of this study is to reveal an basic mechanism of such information processing for several kinds of movements, and to make computational models for this processing.

This paper examines the "internal model control hypothesis" as a fundamental motion control mechanism in the brain from behavioral, computational and physiological view points. Experimental results of measuring arm-stiffness during point to point movements are first shown to criticize the "virtual trajectory control hypothesis" which is considered an alternative to the "internal model control hypothesis". Then physiological, clinical and neuroanatomical data are joined to emphasize the hypothesis that internal models of controlled objects (e.g., eye and limbs) should be acquired in the cerebellum so as to smoothly and desirably control these objects. To support this hypothesis by experimental results, the relationships between eye movements and cerebellum Purkinje cell activities were analyzed. Moreover, several computational schemes for acquiring the internal models of controlled objects (e.g., inverse dynamics models) and mechanisms for utilizing these internal models are examined by using artificial neural networks, and some simulation results are shown. The abstract of each section is shown below.

Several researchers found that the human hand trajectories in Cartesian space during point to point movements, which are almost always spatially straight and temporally bell-shaped, perform consistently even though there exists an infinite number of possible trajectories capable of satisfying the boundary constraints (i.e., start and end positions). And recently, the computational theory for planning trajectories and controlling movements has been discussed. In these discussions, two types of hypotheses were proposed to explain how the higher CNS (i.e., Upper nervous system from spinal cord) produces the commands for controlling voluntary upper limb movements. In one of the two types, e.g. "end point hypothesis" or "virtual trajectory control hypothesis", the higher CNS sends the 'desired end position' (under the end point hypothesis) or the 'desired trajectory' (under the virtual trajectory control hypothesis) of a movement to the spinal cord and musculoskeletal system; and the higher CNS need not to be concerned about the dynamic properties of the controlled objects. Conversely, in the other type, e.g. "internal inverse model control hypothesis", the higher CNS acquires the internal models of controlled objects in order to execute all desirable smooth movements. These contradicting hypotheses are examined in Section 2 by showing experimental results of stiffness measurements during movements.

The stiffness of the arm of the musculoskeletal system which is driven by agonist and antagonist muscles corresponds to the positional feedback gain of a manipulator which is controlled by feedback signal. To examine the control strategy of the human arm movements,

stiffness values of the arm at the different hand positions during movements were estimated by using the time-varying linear second-order variational equation. The stiffness values estimated during movements parallel to the frontal-horizontal axis were not significantly higher than the stiffness values estimated during static posture control at identical positions.

Here, assuming a manipulator which is controlled by a feedback controller with low feedback gains and has similar kinematic structure to the human arm, it is realized that although desired hand trajectories which is inputs to the feedback controller are straight in Cartesian space, the obtained hand trajectories will actually not be straight because of the effects of nonlinear interaction forces such as Coriolis and centrifugal forces. To avoid this shortcoming and to obtain desired hand trajectories for a feedback-controlled manipulator during high-speed movements, high feedback gains are necessary, then, the stiffness of the manipulator get to be high. Feedforward control using internal model of controlled object is a possibility for achieving the desired trajectories. In this case, high feedback gains are not necessary.

Thus, the experimental result, "low stiffness during movements", supports the "internal model control hypothesis" under which the feedforward compensatory commands are assumed to be sent from the higher CNS to the musculoskeletal system, rather than the "virtual trajectory hypothesis" under which straight trajectories could not be obtained by specifying straight desired trajectories (which can be called virtual trajectories or equilibrium trajectories) considered to be sent from the higher CNS to the spinal cord and musculoskeletal system.


Section 3 examines two new learning schemes in which artificial neural networks are used as nonlinear adaptive controllers, and shows how good performance is achieved by the internal models of controlled objects which are acquired by proposed learning schemes. Both schemes are extensions of the "feedback-error-learning" method which was proposed for obtaining an inverse dynamics model functioning as a feedforward controller. In one scheme called "inverse dynamics model learning", the produced autonomous and constrained responses coincide with the reference responses since an approximate inverse model of the controlled object in the neural network feedback controller is acquired by learning. In the other scheme called "nonlinear regulator learning", the produced autonomous responses coincide with the reference autonomous responses since adequate feedforward and feedback controllers consisting of a part of an inverse model of the controlled object are acquired. Both schemes can be regarded as a kind of "model reference adaptive control" (MRAC). The convergence properties of these learning schemes are discussed in the stochastic space by applying Lyapunov's second method and Geman's theorem. Moreover, their efficiency is shown by several simulation results obtained while controlling an inverted pendulum and manipulator, and the relations between the proposed schemes and the previous control methods based on the control theory are discussed.

Section 4 discusses where and how the CNS acquires the internal models of controlled objects, e.g. eyes and limbs, for smooth control. The functional modeling of the information processing of the CNS should be examined under anatomical or physiological constraints such as connections between neurons and neuronal activation patterns during movements. Based on previous physiological, anatomical and behavioral observations, a unified model of cerebellum motor learning by "feedback-error-learning" is proposed. Simulation results are shown for vestibulo-ocular reflex (VOR) adaptation, whose neural circuit and physiological adaptation mechanism have been studied well; the simulation was performed based on the feedback-error-learning scheme.

Moreover, in Section 5, results are given of an analysis on the relations between eye movements and activities of the cerebellum during eye reflex movements (ocular following responses); this analysis examined the plausibility of the cerebellum internal model control hypothesis. In this analysis, the firing frequencies of Purkinje cells which send the outputs of the cerebellum were reconstructed by inverse dynamics expression which has eye acceleration, velocity and position terms. The ratio between the acceleration and the velocity coefficients which were estimated by the least squared error method, has good agreement with that of eye motor neurons, and this result strongly indicates that the dynamic components of motor commands for eye movements of this type are produced by the cerebellum.

The above discussions are about the acquisition and the availability of the internal models of some inherent body parts, e.g. such as eye-balls or limbs. The motor commands for quick predictive movements in the interaction with external objects should be produced by utilizing estimation or prediction of the kinetic properties of external objects. To predict the kinetic properties of external objects such as weight, size and shape, a kind of the internal models of the external objects might be obtained through past experiences. Section 6 examines a manipulation task as a case study of interaction with external objects. A new learning scheme is proposed for acquiring models of external manipulated objects, rather than inherent body parts, and achieving the desired motion by utilizing these external object models. From simple observations of object manipulation behaviors, a manipulation task may be divided into an "object control task" and an "object discrimination task". In the proposed learning scheme, the recognition module called the "gating network" selects or combines control modules forming a so-called "expert network" which acts as a feedforward controller after learning. The recognition ability is simultaneously improved along with the control ability by this 'modular network learning', and finally suitable motor commands are produced for each manipulated object to track the desired trajectories. This scheme was applied to a one-dimensional trajectory tracking task in which the mass, viscosity and stiffness of the controlled objects were changed. The proposed learning scheme might be a potential fundamental model for the higher motor center to construct an external world model.

The results of this study can be summarized as follows. (1) It is demonstrated that to achieve desirable voluntary arm movements the central nervous system utilizes the internal-model control strategy rather than the virtual trajectory control strategy which does not explicitly take the dynamic properties of the controlled objects into consideration. (2) A computational scheme of cerebellum motor learning has been proposed in which the internal models of eye-balls and limbs are acquired in the cerebellum by feedback-error-learning; physiological and anatomical aspects are considered. (3) Several learning schemes have been proposed in which the internal models of the controlled objects are acquired by feedback-error-learning. Proposed schemes may practically be available for controlling objects difficult to be modeled by conventional methods.



目次

	page
第1章	
序論.....	1
1.1 はじめに.....	1
1.2 従来の研究の概要.....	2
1.2.1 腕の随意運動のための脳の計算理論.....	4
1.2.2 内部モデル獲得による運動制御.....	7
1.2.3 小脳における運動の学習.....	7
1.3 本研究の目的.....	8
1.4 本論文の構成.....	9
第2章	
手先スティフネス計測による「仮想軌道制御仮説」の検討.....	11
2.1 はじめに.....	11
2.2 計測装置.....	13
2.3 実験方法・データ処理.....	15
2.3.1 実験の構成.....	15
2.3.2 静止中のスティフネスの計測.....	16
2.3.3 運動中のスティフネスの計測.....	17
2.3.4 スティフネスの計算.....	18
2.4 実験結果.....	19
2.4.1 摂動の種類に依存したスティフネス.....	19
2.4.2 静止中と運動中のスティフネスの比較.....	21
2.5 考察.....	21
2.5.1 摂動パターンによるスティフネスの変化の理由.....	21

2.5.2 運動中のステイフネスが上昇しない理由.....	23
2.5.2 内部モデルを必要としない仮想軌道制御仮説に対する反論.....	23
2.6 まとめ.....	24

第3章

神経回路モデルを用いた

「フィードバック誤差学習」による閉ループ系の学習制御.....	25
3.1 はじめに.....	25
3.2 学習型非線形フィードバック制御.....	28
3.2.1 逆モデル学習.....	29
3.2.2 非線形レギュレータ学習.....	33
3.3 シミュレーション結果.....	35
3.3.1 逆モデル学習による倒立振子制御.....	36
3.3.2 非線形レギュレータ学習による倒立振子制御.....	39
3.3.3 2リンクマニピュレータの学習型インピーダンス制御.....	42
3.4 考察.....	48
3.4.1 逆モデル学習と非線形レギュレータ学習の比較.....	48
3.4.2 神経回路モデルによる他の学習・適応制御手法との関係.....	50
3.4.3 インピーダンス制御の学習による獲得の重要性.....	52
3.5 まとめ.....	53

第4章

小脳における運動学習適応系の計算モデル.....	55
4.1 はじめに.....	55
4.1.1 小脳の信号伝達系・適応機構・役割.....	56
4.1.2 小脳における運動学習モデルの研究.....	57
4.2 小脳における運動学習適応系の統一スキーム.....	60
4.3 小脳運動学習とフィードバック誤差学習.....	61

4.4 小脳片葉における眼球運動適応学習系.....	64
4.4.1 前庭動眼反射・視機性眼球反応適応系を構成する神経回路.....	65
4.4.2 前庭動眼反射・視機性眼球反応適応系モデル.....	66
4.4.3 前庭動眼反射・視機性眼球反応適応系のシミュレーション.....	68
4.5 小脳虫部・中間部における姿勢・歩行制御学習系.....	72
4.5.1 姿勢・歩行制御系と小脳の関係.....	73
4.5.2 小脳虫部・中間部における神経回路の構成.....	73
4.5.3 フィードバック誤差学習に基づく姿勢・歩行制御学習系の概念的スキーム.....	75
4.6 まとめ.....	78

第5章

小脳神経活動の解析.....	79
5.1 はじめに.....	79
5.2 実験条件と解析データ.....	80
5.3 解析手法.....	83
5.4 解析結果.....	84
5.4.1 条件別のデータによる解析.....	84
(1) データの選択.....	84
(2) プルキンエ細胞発火パターンの再構成.....	87
(3) 係数の信頼性.....	91
5.4.2 プルキンエ細胞別のデータによる解析.....	92
5.5 考察.....	93
5.5.1 順モデル表現による解析手法との比較.....	93
5.5.2 モデル次数の検討.....	94
5.5.3 運動に対する小脳の関与.....	96
5.5.4 小脳における運動司令生成のための内部モデル.....	97
5.6 まとめ.....	97

第6章

運動学習による操作対象物の認識と制御.....	99
6.1 はじめに.....	99
6.2 操作対象物の認識.....	100
6.3 モジュラ構造を持つ神経回路モデルによる対象物操作の学習.....	101
6.4 操作対象物数がExpert Network数と等しい場合の学習のシミュレーション.....	103
6.4.1 体性感覚情報を利用した対象物操作の学習.....	105
6.4.2 視覚情報を利用した対象物操作の学習.....	109
6.4.3 視覚・体性感覚情報を利用した対象物操作の学習.....	113
6.4.4 未学習の対象物に対する応答.....	115
6.5 多数の操作対象のための内部表現の獲得.....	117
6.5.1 学習シミュレーション結果.....	117
6.6 考察.....	119
6.6.1 学習パラメータの設定.....	119
6.6.2 適応制御のアプローチとの比較.....	120
6.7 まとめ.....	121

第7章

結論.....	122
---------	-----

付録.....	126
---------	-----

第2章付録.....	126
------------	-----

2-A スティフネスと平衡位置の関係.....	126
-------------------------	-----

2-B Flashの仮定した運動中のスティフネス.....	127
-------------------------------	-----

2-C 係数の最小二乗推定.....	128
--------------------	-----

第3章付録.....	128
------------	-----

3-A Multi Layerd Perceptron (MLP) の学習アルゴリズム.....	128
--	-----

3-B 逆モデル学習の収束性の検討.....	129
------------------------	-----

3-C	非線形レギュレータ学習の収束性の検討.....	133
3-D	マニピュレータのインピーダンス制御.....	136
第4章付録.....		137
4-A	小脳 Smith predictor 説.....	137
4-B	フィードバック誤差学習を検証するために提案する生理実験.....	139
4-C	VOR小脳適応説における生理学データの矛盾.....	140
4-D	前庭器官からの信号, 誤差信号および運動指令の座標系.....	140
4-E	神経発振器と歩行運動.....	142
4-F	下オリーブ核からの信号が誤差を表現していることを示唆する実験.....	143
第5章付録.....		144
5-A	各データセットのトレース数と決定係数の関係.....	144
5-B	最小二乗法により求めた係数の推定誤差.....	145
5-C	従来調べられたP-cell発火頻度と運動の関係との比較.....	147
5-D	C _p 統計量によるモデルの選択.....	148
参考文献.....		150

記号一覧

第2章

x	position vector of DDM hand grip (= human subject hand position)
x_r	reference vector of x
θ	joint angular position vector of DDM link
Ψ	Transfer function from joint coordinates to Cartesian coordinates
J	Jacobian matrix of Ψ
K_a, K_v, K_p	acceleration, velocity and position feedback gains
G_1, G_2	force sensor input gain, motor command integration gain
Φ	Nonlinear function of a human subject arm dynamics
κ	motor command signal from higher motor center of a subject

$\begin{bmatrix} M_{xx}(t) & M_{xy}(t) \\ M_{yx}(t) & M_{yy}(t) \end{bmatrix}$ Inertia matrix of a human subject arm in Cartesian coordinates

$\begin{bmatrix} B_{xx}(t) & B_{xy}(t) \\ B_{yx}(t) & B_{yy}(t) \end{bmatrix}$ Viscosity matrix of a human subject arm in Cartesian coordinates

$\begin{bmatrix} K_{xx}(t) & K_{xy}(t) \\ K_{yx}(t) & K_{yy}(t) \end{bmatrix}$ Stiffness matrix of a human subject arm in Cartesian coordinates

第3章

f	controlled object function
$\ddot{\theta}, \dot{\theta}, \theta$	acceleration, velocity and position of controlled object in joint space
$\ddot{\theta}_r, \dot{\theta}_r, \theta_r$	reference acceleration, velocity and position in joint space
τ	total input of the controlled object
τ_c	CFC (conventional feedback controller) output
τ_n	NNFC (neural network feedback controller) output
τ_{imag}	$= \tau - \tau_n = \tau_c + \tau_{ext}$
K_2, K_1, K_0	acceleration, velocity and position feedback gain in CFC
Φ	neural network function
Φ_d	objective function for neural network controller
w	internal parameter (synaptic weight of neural network)

\hat{w}	ideal internal parameter (ideal synaptic weight of neural network)
η	learning rate coefficient matrix which is positive definite
R	inertia matrix. (i.e. acceleration dependent property of controlled object)
N	velocity and position dependent nonlinear property of controlled object.
F_c	feedback controller output in Cartesian space
M, B, K	mass, viscosity and stiffness gain matrix which determine the desired impedance property of controlled object.
\ddot{x}, \dot{x}, x	actual (observed) acceleration, velocity and position vector
$\ddot{x}_r, \dot{x}_r, x_r$	reference trajectory acceleration, velocity and position vector
$\ddot{x}_e, \dot{x}_e, x_e$	error acceleration, velocity and position vector in Cartesian space
F_{ext}	external force in Cartesian space
J	Jacobian matrix which satisfies $\dot{x} = J(\theta)\dot{\theta}$
I	unity matrix

第4章

T_{wr}	transfer function from world coordinates to retinal coordinates
T_{wc}	transfer function from world coordinates to canal coordinates
θ_h^w	head position in world coordinates
θ_{ext}^w	environmental (external seen) position in world coordinates
θ_e^w	eye ball position in world coordinates
\dot{e}^r	retinal slip signal in retinal coordinates
u^m	motor command in motor coordinates

第5章

$\ddot{\theta}(t), \dot{\theta}(t), \theta(t)$	acceleration, velocity and position of eye at time t
M, B, K	coefficients of $\ddot{\theta}(t), \dot{\theta}(t), \theta(t)$ used in reconstructing P-cell firing frequency by 2nd-order inverse model
δ	dead time (pure delay) between P-cell neural firing and eye movement
$\hat{f}(t - \delta)$	reconstructed P-cell neural firing rate at time $t - \delta$
f_{bias}	bias firing rate
R^2	coefficient of determination
$f(t)$	observed P-cell neural firing rate (ensemble averaged)

\bar{f}	temporal average of $f(t)$
M_m, B_m, K_m	coefficients of $\ddot{\theta}(t), \dot{\theta}(t), \theta(t)$ used in modeling eye motor-neuron firing frequency
f_i	i -th P-cell neural firing rate
$f_{r,i}$	neural firing in other brain regions
J, M, B, K	coefficients of $\ddot{\theta}(t), \dot{\theta}(t), \theta(t)$ used in reconstructing P-cell firing frequency by 3rd-order inverse model

第6章

u'	quasi-target vector of feedforward motor command
u	motor command
u_{fb}	feedback motor command
u_i	i -th expert network output
σ_i	variance scaling parameter of the i -th expert network
g_i	i -th output of the gating network
s_i	weighted input received by the i -th output unit
u_{ff}	total output of the modular network
X	input vector of the gating network
w_{gate}	gating network weight
$w_{expert i}$	i -th expert network weight
$\eta_{gate}, \eta_{expert i}$	learning rate in each network
$g(il X, u')$	posterior probability
M, B, K	mass, viscosity and stiffness, of the object
Ψ_i, Ψ_{ji}	nonlinear function
x_d	desired trajectory vector which consists of acceleration, velocity, and position
x	actual trajectory vector which consists of acceleration, velocity, and position
V	retinal matrix value set
$\alpha, \alpha^*, \alpha', \beta, \beta^*, \beta', \gamma, \gamma'$	object name

図説・表説 一覽

Figure captions	page
Fig. 1.1 Schematic figures of the final position control hypothesis in a single joint musculoskeletal model. (a) Simplified single joint musculoskeletal model. (b) Agonist and antagonist muscle length-tension curves and equilibrium positions. (c) motor command from CNS (solid line) and realized trajectory (dashed line).....	4
Fig. 1.2 Controversial competitive models of muscle motor control by CNS (central nervous system). a) Virtual trajectory control hypothesis. b) Internal model control hypothesis.....	6
Fig. 1.3 The purpose and flow of this research.....	10
Fig. 2.1 A graphical representation of the equilibrium trajectory control hypothesis with high stiffness and low stiffness.	12
Fig. 2.2 Configuration of DDM control system.....	14
Fig. 2.3 Block diagram of the control scheme for DDM.....	14
Fig. 2.4 Coordinates of DDM and a subject	16
Fig. 2.5 Difference in static stiffness values of subject B due to the perturbation patterns in posture control. a) perturbation pattern A, b) perturbation pattern B	20
Fig. 2.6 Estimated mass, viscosity and stiffness of xx-directional parameters during movement and those during static posture control. A) subject A, B) subject B.....	22
Fig. 3.1 Three computational schemes for learning inverse dynamics model of a controlled object which acts as a feedforward controller.....	27
Fig. 3.2 Block diagram of inverse dynamics model learning (IDML).	30
Fig. 3.3 Block diagram of learning impedance control.	32
Fig. 3.4 Block diagram of nonlinear regulator learning (NRL).....	34

Fig. 3.5 Time courses of synaptic weights (adaptive parameters) during IDML.37

Fig. 3.6 Moving averages of the square of the NNFC output and the square of the error for NNFC during IDML.37

Fig. 3.7 (a) The responses of the controlled object for external input in three conditions (Controlled by linear controller, Before learning, After learning), (b) NNFC and CFC output responses after learning.39

Fig. 3.8 Three layered neural network for NNFC used in nonlinear regulator learning.....39

Fig. 3.9 Moving averages of the square of the NNFC output and the error for the NNFC during NRL.....41

Fig. 3.10 (a) The responses of the controlled object from initial position of 1.05[rad]. (b) The responses of the controlled object from initial position of 0.524[rad].....41

Fig. 3.11 CFC and NNFC output during autonomous response after IDML.42

Fig. 3.12 (a) Moving average of squared error and squared NNFC output. (b) Sinusoidal trajectory in the learning period for first 2000 iterations.....44

Fig. 3.13 Free movement following reference trajectory. (a) before learning, (b) after learning.44

Fig. 3.14 Time courses of free response of X, Y axis following reference trajectory.....45

Fig. 3.15 Improved response for the force inputs at the end effector. (a) Trajectories in Cartesian space. (b) Time courses for the x-axis direction step force input at the end effector. (c) Time courses for the y-axis direction step force input at the end effector.46

Fig. 3.16 Free movement & contact task before learning.
 (a) Trajectory of end effector, (b) External force for the end effector.....47

Fig. 3.17 Free movement & contact task after learning.
 (a) Trajectory of end effector, (b) External force for the end effector.....48

Fig. 3.18 IDML and NRL scheme by using back-propagation through a forward model.51

Fig. 4.1 Structure and signal flow of cerebellar cortex.56

Fig. 4.2 Feedback error learning as a learning mechanism model at lateral cerebellum for

voluntary movement.	59
Fig. 4.3 Schematic diagram showing how cerebellar motor learning might be incorporated in sensory-motor control.	61
Fig. 4.4 Schematic diagram of neuronal circuit for horizontal vestibulo-ocular reflex and optokinetic response.	65
Fig. 4.5 Block diagram of adaptive modification of vestibulo-ocular reflex and optokinetic response.	67
Fig. 4.6 Time courses of eye, head, external world and desired eye position during learning.	70
Fig. 4.7 Time courses of the gain parameters for each flocculus input (i.e., head velocity, retinal error and feedback motor command) during learning simulation.	70
Fig. 4.8 Time courses of the moving averages of the squared retinal error and the squared flocculus Purkinje-cell output during learning simulation.	71
Fig. 4.9 VOR responses and OKR responses (i.e., eye position responses for sinusoidal head movement and external world movement) before learning and after learning.	71
Fig. 4.10 (a) Schematic diagram of neural circuit of posture control in vermis.	74
Fig. 4.10 (b) Schematic diagram of neural circuit in intermediate part of hemisphere.	75
Fig. 4.11 Schematic block diagram for learning mechanisms of (a) posture control in vermis and of (b) locomotion control in intermediate cerebellum based on feedback-error-learning, which are associated by the modeling of voluntary movement learning mechanism in lateral cerebellum and of VOR/OKR adaptation mechanism in flocculus.	77
Fig. 5.1 (a), (b) Configuration of the experiment. (c) Activity recording site, VPFL (ventral paraflocculus).	81
Fig. 5.2 Main pathway for generating ocular following responses.	82
Fig. 5.3 Ensemble averaged data of 194 trials in same stimulus condition.	83
Fig. 5.4 Histogram and quantile box plot of coefficient of determination.	85
Fig. 5.5 The relation between relative coefficients of determination and relative time lag, δ , of	

data sets whose coefficient of determination at the maximum point were over 0.7.....	86
Fig. 5.6 (a) Reconstructed and observed VPFL P-cell firing pattern. (b) Components of reconstructed firing frequency ascribed to eye angular acceleration, angular velocity and angular position.....	87
Fig. 5.7 Histogram and quantile box plot of estimated time lag.....	88
Fig. 5.8 Histograms and and quantile box plots of estimated coefficients	89
Fig. 5.9 Nominal categorization of estimated coefficients and estimated time lag. a) by P-cell b) by stimulus velocity.....	90
Fig. 5.10 Distribution of 95% confidence intervals of each estimated coefficient.....	91
Fig. 5.11 Reconstruction of a single P-cell firing frequency by one parameter set of linear model.....	93
Fig. 6.1 Block diagram of the learning scheme for object manipulation using modular architecture	101
Fig. 6.2 Schematic expression of the controlled object and manipulated object.....	104
Fig. 6.3 Temporal patterns of (a) selected object, (b) feedback and feedforward motor command, (c) desired and actual trajectories before learning.	104
Fig. 6.4 The moving average of the squared motor commands (i.e., feedback controller output and modular network output) during learning using somatic information.	106
Fig. 6.5 The time courses of expert network synaptic weights during the learning in which somatic information was used as the gating network input.	107
Fig. 6.6 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands (i.e., feedback controller output and modular network output), (d) desired and actual trajectories after the learning using somatic information.	108
Fig. 6.7 Gating network outputs v.s. objects using somatic information.	109
Fig. 6.8 Visual cues and object characteristics in the learning using visual information.	110
Fig. 6.9 The moving average of the squared motor commands (i.e., feedback controller output and modular network output), and the time courses of expert network synaptic weights during	

the learning using visual information.	111
Fig. 6.10 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands, (d) desired and actual trajectories after the learning using visual information.....	112
Fig. 6.11 Gating network outputs v.s. objects using visual information.	112
Fig. 6.12 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands, (d) desired and actual trajectories after learning using somatic and visual information.	114
Fig. 6.13 Gating network outputs v.s. objects using somatic and visual information.	114
Fig. 6.14 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands, (d) desired and actual trajectories, during an trajectory tracking task with unknown objects using somatic information.	116
Fig. 6.15 Gating network outputs v.s. objects during an trajectory tracking task with unknown objects using somatic information.	116
Fig. 6.16 Sample objects (small spheres) and acquired internal model in ExptNets (big spheres) represented in M, B, K (mass, viscosity, stiffness) parametric 3D-space.	118
Fig. 6.17 Temporal patterns of (a) the objects, (b) the motor commands, (c) the desired and actual trajectories, after learning.....	119
Fig. 2-A.1 a) One degree of freedom muscle-link model. b) Simplified length-tension (torque) curves of agonist and antagonist muscles.	126
Fig. 4-A.1 Learning motor control by cerebellum with internal model of controlled object. (A) Compensatory control by the forward model of a controlled object proposed by Miall. (B) Compensatory control by the inverse model of controlled object.	138
Fig. 4-A.2 Transformed block diagram of the combined scheme of feedback-error-learning and Smith predictor.....	138
Fig. 4-B.1 Proposed target-change experiment under normal and mirror-image coordinate transformations which reveals the reference coordinates in which climbing-fiber responses are represented.	139
Fig. 4-D.1 Three coordinate frames for VOR adaptation	

Fig. 4-D.2 (a) Geometry of eye muscles and semicircular canals of a rabbit.

(b) Geometrical axes of IO signal, muscles and semicircular canals in left eye.142

Fig.5-A.1 Trace number for ensemble averaging V.S. coefficient of determination

of each data set144

Table captions..... page

Table 1.1 Previous research and background of computational neuroscience of motor control....3

Table 3.1 Parameters of 2-link manipulator42

Table 3.2 Summary of differences between IDML and NRL49

Table 3.3 Sensing signals and prepared calculation in three methods of impedance control.....52

Table 4.1 Principal input and output of each cerebellar region.....57

Table 5.1 Coefficient of determinations obtained by fitting between estimated coefficients and nominal categorization by P-cell and stimulus velocity..89

Table 5.2 Significance of each component in the reconstructed firing frequency.....95

Table 6.1 Object characteristics105

Table 6.2 Sample objects118

Table 4-F.1 Experimental results which suggest IO (inferior olive) signal encodes performance or motor-command error143

第1章

序論

1.1 はじめに

動物あるいは人間がどのようなメカニズムによって動いているのかということは、はるか昔より人類の飽くなき興味の対象であった。18世紀頃盛んに制作された動物や人間を真似たぜんまい仕掛けの自動機械も、そういった興味に端を発して作られたものである。動きを司る機能が脳にあることが実験的にも明確になってきたのは、19世紀初頭のころのことである¹⁾。以後、中枢神経系の情報処理機構を理解しようという試みは、様々なアプローチによって行われてきた。しかし脳は、21世紀最大の研究テーマの1つと言われるほど、依然未知の部分が多く残されている。多くの学問が専門化・細分化されてゆくのに対して、脳という1つのシステムを理解しようとするためには、生理学、解剖学、情報工学、制御工学、行動心理学など多くの学問による学際的アプローチを必要とし、それらを有機的に結び付けて考えることが必要になってくる。

さて、我々は日常生活の中で多くの運動を”思いどおり”に遂行しているが、”思ったとおりに動かない”という局面にしばしば出会う。これは、自分の思ったとおりに動かすための運動指令を出すことができなかった、あるいは出したにも関わらず制御対象の特性に変化が生じて思いどおり動かなかった、ということであろう。いずれにしろ、その時の状況において適切な運動指令ではなかったということである。生体系の様に大きな遅れを持つシステムでは、フィードバックにより運動結果の修正をしていたのでは速く正確な運動は実現できない。どのような運動指令を生成すれば目的とする運動が達成できるかが前以てわかるためには、制御対象がどのような運動特性を持つのかを中枢神経系があらかじめ知っている、すなわち制御対象の「内部モデル」を持っていることが必要とされる。

本論文は、中枢神経系による運動機能を実現する情報処理の中で、特に、その内部モデル学習のメカニズムに焦点を当て、そのメカニズムが脳の「どこで」「どのように」行われているかを学際的視点から考察し、さらに学習系のモデル化により生体に備わった幾つかの機能を再現することで、そのメカニズムの基本構造についての解明・理解を

試みた結果をまとめたものである。

1.2 従来の研究の概要

脳の研究では、神経回路の結合関係や化学反応などの物質的側面以外に、情報処理的側面から取り組むことが重要である。従来、中枢神経系における情報処理メカニズムを解明していくための研究は、1つ1つの神経細胞の挙動を調べる神経生理学などのミクロな視点のレベルから、心理物理実験などにより、反応・現象から直接に情報処理のメカニズムを探ろうという認知科学のようなマクロな視点に立ったアプローチのレベルまで、様々な段階・側面から行われてきた。また、神経回路の数理的なモデルを仮定し、その能力や挙動を計算するといったような理論的研究も少なからず行われてきた²⁾。

また近年これらの研究に加え、神経回路モデルを用いて、中枢神経系で行われている機能の一部をシミュレーションすることにより、その情報処理メカニズムを理解しようというアプローチが、計算機の高性能化に伴って盛んに行われている^{3,4)}。

それらの多くの脳のメカニズム解明に対するアプローチの中から、本論文に関連する従来の研究の流れをTable 1.1に示す。そしてその中から、随意運動の学習のための脳の計算理論、内部モデル獲得による運動制御、小脳での運動学習、について概要を以下に説明する。本論文の各章に関連する各々の従来研究の詳細については、各章のまえがきにまとめる。

Table 1.1 Previous researches and hypotheses of computational neuroscience for motor control

	1960	1970	1980	1990
中枢神経系による運動制御モデル化		小脳パセプトロンモデル (Marr 1969; Albus 1971) 随意運動制御に関わる脳部位 (Allenら 1974) 姿勢制御中の運動司令の調整メカニズム (Feldman 1966)	小脳適応フィルタモデル (Fujita 1984) フィードバック誤差学習 (Kawatoら 1987) トルク変化最小軌道仮説 (Unoら 1989)	小脳運動学習モデル (Kawato, Gomi 1992) トルク変化最小軌道仮説 (Flash 1987) 小脳適応ミス補償器仮説 (Mial 1989) VOR適応モデル (Lisbergerら 1992)
小脳の解剖学的構造の解明		小脳の解剖学的構造の解明 (Ecclesら)	IOからのRetinal slip信号 (Simpsonら 1974) ネコ歩行中の小脳単純・複雑スライク (Udoら 1981)	Visuo-motor taskと小脳 (Miall 1987)
小脳の学習機能の観察		VOR小脳適応実験 (Itoら 1975)	VOR, OKR 適応実験 (Nagaoら 1983-) LTD, LTP in Vitro (Sakurai 1987)	LTD, LTP In Culture (Hirano 1990) IO signal 座標系 (Simpson 1989) OFRと小脳VPFL (Shidaraら 1993)
小脳の生理学的研究		小脳マイクログリオン (Oscasspn 1976) 適応姿勢制御と小脳 (Nashner 1976)	追跡性眼球運動と小脳VPFL (Miles 1980-)	
筋骨格系ダイナミクスの計測・モデル化の研究		筋のモデル (Akazawa, Zahalak, Winter) 求心性神経切断サルによる腕運動の実験 (Bizziら 1979)	人腕静止中の手先ステイフネスの計測 (Mussa-Ivaldiら 1985; Flashら 1990) 人腕静止中の単関節ステイフネスの計測 (Lacquaniti 1982; Mackey 1986)	足首関節のステイフネス (Kearneyら 1992) モデルによる仮想軌道と運動中のステイフネスの予測 (Katayamaら 1992) 人腕運動中の単関節ステイフネスの計測 (Benettら 1992) 人腕運動中の手先ステイフネスの計測 (Gomiら 1992)
運動学習モデルとしてのニューラルネット(NN)の研究			NN研究再興 IKM, IDDMのNNによる学習 (1985-)	カスケードネットワークによるトルク変化最小軌道 (Kawato 1990) NNによる筋電図から運動の推定 (Koike 1993) 神経回路モデルを使った非線形学習制御 (Gomi, Kawato 1990) 順逆モデルによるトルク変化最小軌道 (Wadaら 1992)
マニピュレータ制御の研究		Computed torque法 (Paul 1972)	線形適応制御の利用 (Dubowsky 1979) 能動的力制御 (Salisbury 1980) ハイブリット制御 (Raibertら 1981) インピーダンス制御 (Hogan 1985) 適応型ロボット軌道制御 (Slotine 1986-)	Computed torque法 (1984-)

1.2.1 腕の随意運動のための脳の計算理論

高等動物特有の前肢のバラエティに富んだ機能的活用は、多くの研究者の興味の対象であろう。腕の随意運動制御の方策の説明としては、従来いくつかの仮説^{6,9)}が提案されてきた。

従来から知られているように、筋骨格系はFig.1.1(a)のようなバネ・リンク系でモデル化することができ、運動の際のトルクは主働・拮抗する筋群の張力の差によって生ずる。これは筋の長さ—張力曲線で表される筋の特性から得られる主働・拮抗筋の釣り合い点（平衡点）を移動させ、不釣り合いを生じさせることに相当する（Fig.1.1(b)）。Bizziら⁶⁾はこの点に着目し、目標位置への随意運動では、Fig.1.1(c)に示すように目標位置を腕の静力学的な釣り合い点とするような司令が運動開始時に階段関数的に上位中枢から出力されているという説明をし、これを「終端位置制御仮説 (Final position control hypothesis)」と呼んだ。しかし、求心性神経を切断したサルにおける腕の単関節運動実験⁵⁾から、上位中枢は運動中に刻々とその力学的平衡位置を変化させていることが解明された。その結果にもとづき、Bizzi⁷⁾, Hogan⁸⁾らは、腕の目標位置への随意運動は平衡位置を運動中に変えていくことで制御が行われているという「仮想軌道制御仮説 (Virtual trajectory control hypothesis)」を提案した。

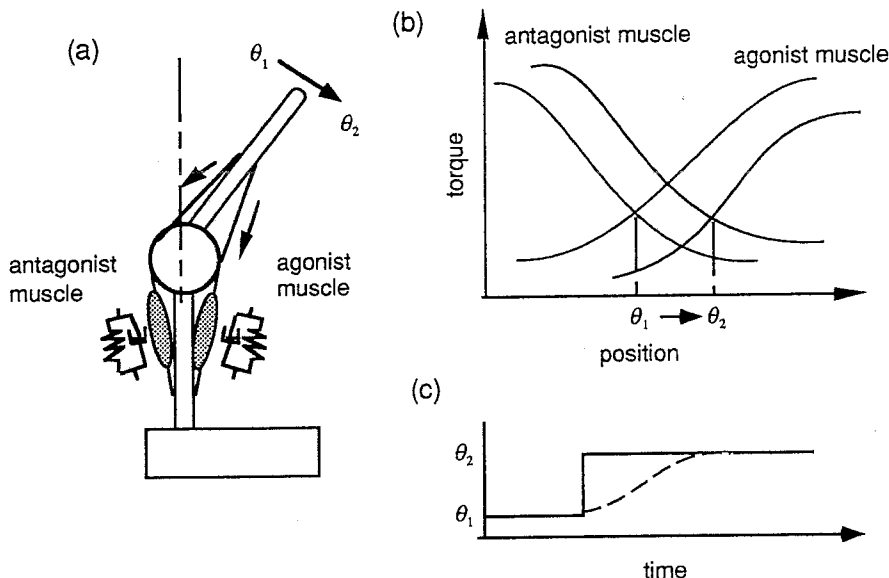


Fig. 1.1 Schematic figures of the final position control hypothesis in a single joint musculoskeletal model. (a) Simplified single joint musculoskeletal model. (b) Agonist and antagonist muscle length-tension curves and equilibrium positions. (c) motor command from CNS (solid line) and realized trajectory (i.e., time course) (dashed line).

一方、腕の随意運動の軌道計画の方策モデルとして、Flashら¹⁰⁾は、肩を含む水平面内における人腕の随意運動中の手先軌道を測定し、「躍度最小軌道仮説」を提唱した。この仮説は、脳は腕の随意運動に対して「作業座標系での手先の躍度^{*}」を最小にするよう計画している、というものである。すなわち、水平面内の運動であれば、ある位置からある位置への手先の移動を、平面上の直線を描くように、時間パターンとしてなめらかな軌道を計画していることになる。さらにFlash¹¹⁾は、腕の様々な静的姿勢でのステイフネスを計測し、「躍度最小軌道仮説¹⁰⁾」とBizziら⁷⁾が提唱した「仮想軌道制御仮説」を組み合わせ、腕運動のシミュレーションを行い、実際の人腕の計測軌道とよく一致することを報告している。すなわち、“脳が司令する「仮想（平衡）軌道」は「躍度最小軌道」として計画され、腕のステイフネスは状況に合わせて設定される” というものであった。しかしそのモデル¹¹⁾では、実現される軌道と躍度最小軌道で指定される仮想軌道をほぼ似たものにするため、運動中の手先のステイフネスがかなり大きくなる（静的な状況でのステイフネス楕円体のサイズの3から6倍）ことを仮定していた。通常筋の活性度が上がると筋の長さ—張力曲線の傾は大きくなる¹²⁾ことから“運動中のステイフネスは静止中のそれに比べ高くなっている”という仮定は自然のように考えられた。

以上をまとめると、Bizzi, Hogan, Flashらの研究の流れでは、Fig.1.2(a)に示すように、中枢神経系は仮想軌道（+ステイフネス）を司令し、下位の神経回路による反射機構や筋の物理的バネ特性に依存して実際の軌道は生成されるのであって、中枢神経系が直接腕のダイナミクスを考慮した運動司令を出力しているのではない、と考えられていると言える。

これに対する考え方⁹⁾として、「脳は制御対象である腕のダイナミクスの内部モデルを獲得しそれを利用することによって、滑らかで正確な運動を実現できるようになる」というものがある。この仮説は、「電気回路と異なり信号の伝達速度が遅い実際の神経回路を使った場合、単なるフィードバック制御に頼るだけで、高速で正確な運動が可能であろうか？」という基本的疑問から発展した考え方で、Fig.1.2(b)に示すブロック図で表される。またこの仮説は、次に述べるロボット制御などの分野で整理されてきたフィードフォワード制御のために必要な計算の考察などとも整合性がある。

ロボット制御の研究分野においては、逆問題を解いてフィードフォワード制御に用いるという手法が1980年代に整理された^{13,14)}。すなわち、作業座標系で要求するロボット

^{*}躍度は、加速度を時間微分したもの

の手先軌道の計画を行い、作業座標系からロボットの関節座標系への変換である「逆キネマティクス問題」、関節の運動からその動作に必要な関節トルクを計算する「逆ダイナミクス問題」を解き、そのトルク指令値で動作させることにより作業座標系での望みの運動を実現しようというものである。高速で正確な運動を特定の運動パターンだけでなく広い作業領域に対して遂行するためには、このような制御対象の内部モデル（逆モデル）を計算することによりフィードフォワード制御をすることが必要条件であり、生体運動系においても同様の制御メカニズムが予想された。

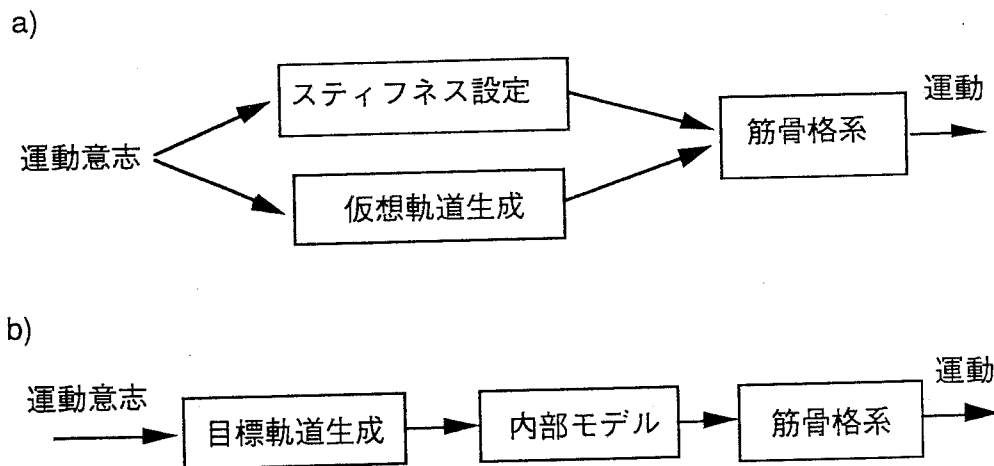


Fig. 1.2 Controversial competitive models of muscle motor control by CNS (central nervous system). a) Virtual trajectory control hypothesis. b) Internal model control hypothesis.

また、上で説明した内部モデルを必要としない軌道計画モデルである「躍度最小軌道仮説」に対しても、宇野ら¹⁵⁾は、腕のダイナミクスが軌道計画の過程で入らないことに疑問を持ち、対立仮説として、腕の内部モデルを必要とする「トルク変化最小軌道仮説」を提案し、経路点を含む軌道、および腕がバネなどで拘束されたときの軌道の計測によりその仮説の優位性を示した。宇野ら¹⁶⁾はその仮説をさらに発展させ、「筋張力変化最小軌道仮説」を提案している。また、宇野らの仮説を神経回路モデルを使って実現する手法としては、川人ら¹⁷⁾の「カスケードニューラルネットモデルによる最適化手法」や和田ら¹⁸⁾の「順逆ダイナミクスモデルによる最適化手法」などがある。

そこで次に、この内部モデル仮説に必要な、内部モデル獲得メカニズムのモデル化の研究について紹介する。

1.2.2 内部モデル獲得による運動制御

さて、内部モデルに基づく運動制御が動物や人間において行われているという立場に立つとすると、その内部モデルが「(計算論的に)どのように」獲得されるのかを説明する必要がある。ロボットなどのような場合、キネマティクスやダイナミクスの個々の特性は、そのシステムを分解して個別に計測することによりある程度モデル化できるが(もちろんモデル化し難い特性もある)、生体系の場合、分解して個々に調べることもできず、またその特性は環境に依存しながら時間の経過と共にしだいに変化してゆく。よって、制御対象の内部モデルが中枢神経系にあるとすると、それはなんらかの学習メカニズムによって獲得される必要があり、その獲得メカニズムのモデルを構築してゆくことは、生態系における内部モデル制御仮説をサポートするうえで非常に重要である。

川人ら⁹⁾はロボット工学での考察から得られた”運動制御問題の階層性”すなわち「軌道計画問題」「逆キネマティクス問題」「逆ダイナミクス問題」と生理学・解剖学で得られた実際の神経系に関する知見などを基に、生体系での随意運動学習制御系のモデルとして、「フィードバック誤差学習」という考え方を提唱した。それは、フィードバック制御器の出力を神経回路モデルの学習の為の誤差信号として用い、神経回路モデルに制御対象の「逆システム」を学習させてフィードフォワード制御をする方法である。

(Fig3.1c参照) この手法は、神経回路モデルに制御対象の逆モデルを学習させる他の方法である「直接逆モデリング」や「順逆モデリング」と異なり、生体系での学習モデルとしてより'もっともらしい'と考えられている。川人らはその学習手法を、産業用マニピュレータ^{19,20)}や遅れの大きい空気駆動型ゴム人工筋マニピュレータ^{21,22)}などの制御対象に適用し、有効性を検証した。これらのフィードフォワード制御のための内部モデル(逆モデル)獲得方法の違いは、3.1において比較説明する。

1.2.3 小脳における運動の学習

前節で述べた「制御対象の内部モデルを利用した運動制御」が動物や人間において行われているという仮説においても1つ説明しなければならないことは、その内部モデルは実際の中枢神経系では「どこで」「(生理学的に)どのように」獲得されるのか、ということである。中枢神経系の情報処理メカニズムをブラックボックスとして、マクロな現象だけを観察してモデル化していたのでは、脳の計算原理を解き明かすことはできない。脳内で起こっているミクロな現象から運動の学習というマクロな現象までを説明することが必要であろう。川人⁹⁾は、Marr²³⁾やAlbus²⁴⁾、Allenら⁹¹⁾、塚原仲晃ら²⁵⁾、

伊藤正男²⁶⁾、藤田昌彦²⁷⁾などの生理学・解剖学・計算論的研究に基づき、内部モデル獲得のための部位として小脳をあげた。

小脳が担っている役割とその情報処理メカニズムおよび学習過程を明らかにしようという研究は、医学・生理学・生物学・解剖学・運動学など様々な分野と関連しながら古くから行われてきた^{26,28,29)}。生理学・解剖学的立場から、小脳をモデル化することに積極的な方向性を示したものとしては、例えば、運動制御のための情報伝達経路を明確化する事に重点をおいた伊藤正男²⁶⁾、Oscarsson³⁰⁾、Brooks³¹⁾などの研究がある。また、小脳での学習のモデル化に計算論を持ち込んだのは、小脳パーセプトロンモデルで有名なMarr²³⁾とAlbus²⁴⁾である。Marr, Albusの小脳パーセプトロン以来、脳の様々な部位に対する計算論的モデル化の研究は盛んに行われるようになった。中でも小脳は、生理学的・解剖学的にもよく調べられ、記憶の基本的メカニズムである信号伝達効率の変化についても、シナプス可塑性の化学反応系から運動学習における役割に至るまで多くのデータが集められ、ある程度説明がつくようになってきている²⁶⁾。

しかし、運動学習との関係は定性的には多くのデータが集められているにもかかわらず、その定量的関係が明らかになっているものは、前庭動眼反射などの特定の運動に限られる。小脳の関与する様々な運動学習と小脳の適応メカニズムがどのような関係にあるのかは一部分しか明確にされていなかった。

1.3 本研究の目的

さて上述のような背景に基づき、中枢神経系による運動機能を実現する情報処理を明らかにしてゆくために、本研究ではスムーズな運動の実現とその適応・学習のメカニズムに焦点を当て、次の3点を具体的な目的とした。

- (1) 従来の研究では未確認であった、内部モデル制御仮説に対立する仮想軌道制御仮説の是非を運動学的実験により検証する。
- (2) 運動の学習に重要な役割を果たすと言われる小脳において、制御対象の内部モデルの獲得が行われているかどうかを、従来の運動学・生理学的実験結果の検討およびデータの解析により明らかにする。
- (3) 内部モデル獲得およびそれを利用するメカニズムを人工神経回路モデル等を用いてモデル化する。

中枢神経系の情報処理メカニズムを理解しモデル化することは、その科学的重要性ば

かりではなく、様々な機械システムや情報処理システムのインテリジェント化、あるいは人間とのインターフェース設計においても有益である。その運動学的側面だけを見ても、生体系がどのような方策により運動を遂行しているかを解明することは、多くの機械・制御システムに新たな方法論を提供することにつながり、工学的にも極めて重要な意味を持つものであると考える。

1.4 本論文の構成

本論文では、上記の目的に従い、人腕運動の計測による仮想軌道制御仮説の検討、なめらかで正確な運動を実現するための適応・学習の中核的機能・メカニズムおよび学習に関連する脳部位についての考察、学習によって獲得される一部の機能を神経回路モデルなどを用いてシミュレーションした結果、について報告する。

まず第2章では、腕の随意運動を制御する脳情報処理機能のモデルとして従来提案されている「仮想軌道制御仮説」、すなわち制御対象の内部モデルを必要としない運動制御仮説、を検証するための運動計測実験（運動中の手先スティフネス計測）結果について述べ、生体系運動制御における制御対象の内部モデルの必要性を検証する。次に第3章で、制御対象の内部モデルを学習により獲得し運動制御性能を向上させていく「神経回路モデルによる学習制御スキーム」について説明し、そのシミュレーション結果を示す。この学習の収束性の理論的考察は付録で述べる。そして第4章では、中枢神経系の「どこで」「どのように」運動制御のための内部モデルを獲得するのか、という問いに答えるための「統一的運動学習モデル」を説明し、解剖学・生理学的データとの対応関係について考察する。また第5章では、電気生理実験によってえられたデータの解析によって得られた、運動と実際の神経活動との関係を述べる。さらに第6章では、比較的高次の運動機能である「対象物操作」を実現する学習についての考察、および神経回路モデルを用いた学習制御モデルとそのシミュレーション結果を示す。本論文を通じてのテーマは、運動のための内部モデル学習という点に絞られるが、扱う対象が多岐に渡るため、各章毎に関連する従来の研究の詳細は各章のはじめにまとめる。そして最後に第7章では、本研究によって得られた知見および今後の研究の展望などを述べる。Fig.1.3に研究の目的と構成をまとめる。

目的

生体運動制御における内部モデル利用に関する考察と
中枢神経系によるその獲得メカニズムのモデル化

運動計測実験による内部モデルの必要性の検討 (第2章)

- ・手先スティフネスの計測実験

内部モデル獲得の計算モデルの提案 (第3章)

- ・神経回路モデルを用いた「フィードバック誤差学習」による学習制御スキームの提案
- ・シミュレーション

小脳で内部モデルを獲得する計算モデルの提案 (第4章)

- ・小脳における統一的運動学習モデルの提案
- ・解剖学・生理学的データとの対応関係の考察

小脳神経活動の解析 (第5章)

- ・逆モデル表現による眼球運動と小脳プルキンエ細胞活動との関係の解析

外界の内部モデルを獲得する計算モデルの提案 (第6章)

- ・対象物操作を実現する学習制御モデルの提案
- ・シミュレーション

Fig. 1.3 The purpose and flow of this research

第2章

手先ステイフネス計測による 「仮想軌道制御仮説」の検討

2.1 はじめに

従来、脳における腕の随意運動制御の方策の説明として、第1章に述べたように2つの代表的な仮説がある。1つは制御対象の内部モデルを使用せずに軌道計画や制御が行われているとする仮説^{5,7,10,11)}、もう1つは、制御対象の内部モデルが学習によって獲得され、それを軌道計画・制御に利用しているとする仮説^{9,15)}である。

1.2.1で触れたように、運動の際のトルクは主働・拮抗する筋群の張力の差すなわち現在位置の平衡位置からのずれによって生じ、その大きさは、主働・拮抗筋群の平衡位置と筋の長さ—張力曲線の傾きすなわちステイフネスによって決定される（付録2-A参照）。Flash¹¹⁾は、人腕の運動計測によってえられた「躍度最小軌道仮説」と筋骨格系の特性と生理学実験によって発想された「仮想軌道制御仮説」とを基本に、内部モデルを必要としない随意運動制御のシミュレーションを行った。そして、実際に実現される人間の手先の軌道と躍度最小となる軌道（計画した軌道）との偏差は、躍度最小軌道（平面上では直線軌道）を仮想軌道として制御するために生じるものであると説明した。すなわち、脳が腕の内部モデルを獲得する必要がないという主張である。しかし、シミュレーションを行ったモデルでは、腕のステイフネスが運動中に高くなることが仮定されている。ここでもし、運動中のステイフネスが高くなっていないと仮定すると、単なる力学的平衡位置の時間パターン（平衡軌道）を運動司令として筋骨格系に与えた場合、その筋骨格系の非線形で干渉し合うダイナミクスの為に、実現される軌道は平衡軌道から大きくずれてしまう。逆に、実現される軌道のある目標軌道に合うようにするためには、ダイナミクスの影響を考慮して、筋骨格系に司令する平衡軌道を実現される軌道からずらして入力しなければならない（Fig.2.1参照）。特に高速な運動の場合、手先を直線的に動かすためには、運動中の遠心力やコリオリ力を補償するため、曲がりくねった平衡軌道を中枢神経系が司令しなくてはならないことになる。中枢神経系が筋骨格系に対して司令する平衡軌道を実現軌道と似たものにするためには、運動中の腕のステイフ

ネスを高くして、腕のダイナミクスの出力位置に対する影響を少なくする必要があり、それゆえFlash³⁷⁾はシミュレーションにおいて静止状態より数倍高いスティフネスを仮定したわけである（付録2-B参照）。

よってFlashのモデルにおいては、腕のスティフネスが高いことは重要な条件であり、この条件が成立しない場合、脳の計算モデルとしての妥当性は大きく減じてしまうことになる。

一方、片山ら^{32,33)}は、6筋2リンクの腕のダイナミクスモデルを用いてシミュレーションを行い、学習によって獲得した内部モデルで制御した場合、ある程度速い運動(400[mm]/500[ms])においてもスティフネスは静止状態と比べてあまり高くなり、そのため仮想軌道である手先の平衡位置の軌道が、実現された軌道と大きく異なってしまうことを確認した。




Fig. 2.1 A graphical representation of the equilibrium trajectory control hypothesis with high stiffness and low stiffness.

AP and EP are, respectively, the actual and equilibrium positions of the hand, and F is the total effective force at the hand position. ET denotes a equilibrium trajectory for realizing a straight hand trajectory.

このような背景から、実際の運動中のスティフネスを計測することにより、随意運動制御の仮説を検証することが、脳の計算論を考える上で重要であると考えられる。

近年、運動中あるいは過渡的な状態の単関節スティフネスの計測が行われている^{34,35)}。Bennettら³⁴⁾は、肘関節1自由度の往復随意運動では、運動中のスティフネスが静止中に比べて減少していることを報告している。しかし、多関節運動中では、肩関節のスティフネスや2関節筋などの影響があるため、手先スティフネスが運動中にどの様に変化するかについては単関節での結果だけから推し計るのには問題が残る。

また、Mussa-Ivaldiら³⁶⁾、Flashら^{11,37)}は静的な状況での手先のスティフネスの計測を行っている。彼らは、(1)手の同じ位置に対するスティフネス楕円体の形状は変わらないこと(大きさは変わる)、(2)被験者や実験を行った時期により計測結果が異なってくることを報告している。さらに、外乱の与え方、計測結果の処理の方法等の実験条件によっても定量的に異なった結果が得られている^{38,39,34)}。そのため、静的なスティフネスと運動中のスティフネスの定量的関係を比較するためには、計測条件(実験装置、被験者、時期)をできる限り等しくする必要があると考える。

そこで本章では、随意運動制御仮説検証のため、多関節運動中の手先スティフネスがどの程度になっているかを、時変線形変分方程式のパラメータ推定を行うことにより調べ、静止時のものと比較した結果について述べる。具体的には、2.2節で説明するダイレクトドライブ・マニピュランダムによって、2.3節に説明する手順で運動中の手先に外乱を与え、また2.3節に説明する方法で、静止中および運動中のスティフネスを計算する。2.4節では条件によって異なるスティフネスの計測結果をまとめ、2.5節でそれらが異なってくる理由について考察する。

2.2 計測装置

運動中に外乱を与えて、その外乱によって生ずる変化から手先のスティフネスを計測するため、Fig.2.2中に示すような先端にハンドルのついたロボット(Direct Drive Manipulandum, 以下DDMと呼ぶ)を使用した。DDMの2つの関節は直接モータによって駆動される方式であり、制御していない状態では、外界からの力によっても柔軟に動作する。Fig.2.2にDDMを制御するためのシステム構成を示す。DDM+モータドライバ(新明和製)、力センサ(ニッタ製 USF3012A-15, 分解能0.003[kg]) 制御用コンピュータ(DSP32C)、パーソナルコンピュータ(PC-H98)により構成される。グリッパの位置はDDMに付属の角度エンコーダ(480000[pulse]/2 PI [rad])により計算し、グリッパとDDMとの間に取り付けた力センサで被験者がグリッパに与える力を計測する。

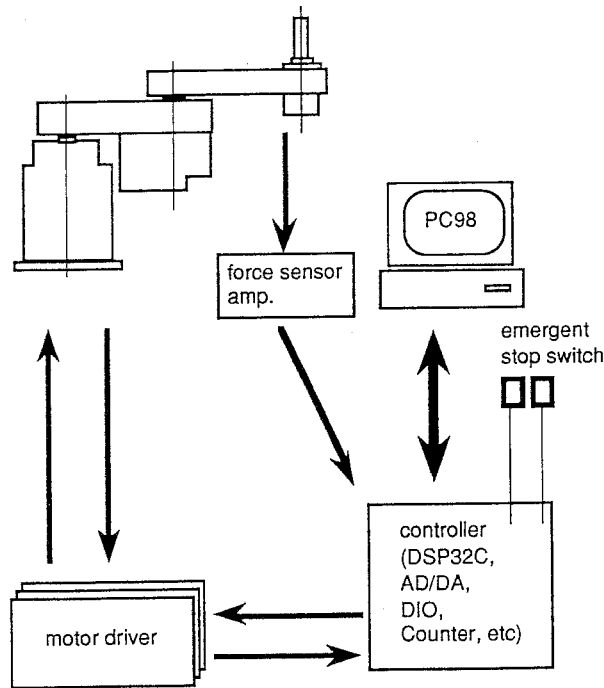


Fig. 2.2 Configuration of DDM control system

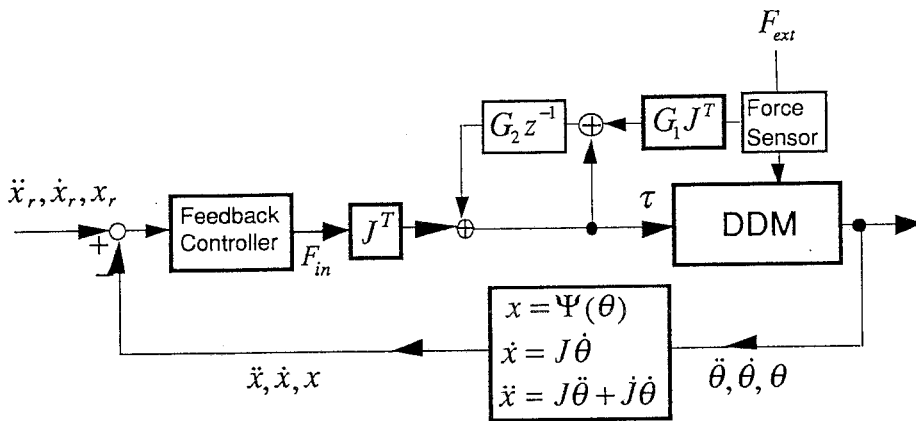


Fig. 2.3 Block diagram of the control scheme for DDM

Fig.2.3は今回の実験で用いた制御系である。 x はデカルト座標系でのDDMグリッパの位置を表すベクトル、 x_r はその指令ベクトル、 θ はエンコーダで観測される関節座標系での位置、 Ψ は関節座標系からデカルト座標系への変換関数、 J はそのヤコビ行列である。 DDM各関節へのトルク出力指令に対し数値積分を用いることにより、制御対象のダイナミクスに関する知識（質量、重心位置、リンク長など）を全く使用せずにイン

ピーダンス制御⁴⁰⁾を近似的に実現して、腕に対する作業座標系での機械インピーダンスをフィードバックゲイン K_a, K_v, K_p によって調節できるようにしている。制御ループの時間は2 [kHz] (0.5[ms/cycle])である。実験において力センサからの入力ゲイン G_2 および運動司令の積分ゲイン G_1 は

$$G_1 = [0.98, 0.97]^T, \quad G_2 = [0.2, 0.2]^T \quad (2-1)$$

とした。また、フィードバックコントローラは、次式に従って計算される。

$$F_{in} = K_a(\ddot{x}_r - \ddot{x}) + K_v(\dot{x}_r - \dot{x}) + K_p(x_r - x) \quad (2-2)$$

ここで K_a, K_v, K_p は位置・速度・加速度ゲインマトリックス、 x_r, x は参照位置ベクトルと現在位置ベクトルで、 $x = [x, y]^T$ である。静止状態のステイフネスの計測では

$$K_a = \text{diag}[1000, 1000], \quad K_v = \text{diag}[60, 60], \quad K_p = \text{diag}[0, 0] \quad (2-3)$$

運動中のステイフネスの計測では

$$K_a = \text{diag}[1000, 0], \quad K_v = \text{diag}[60, 0], \quad K_p = \text{diag}[0, 0] \quad (2-4)$$

と設定した。ゲインの設定からわかるように、運動中のステイフネス計測実験では、x-方向は位置制御されており、y方向は自由に動かせるようになっている。積分器の働きにより、y方向の慣性が減少するように制御されるが、計測時と同様の運動中における、y方向の実効慣性・粘性は、最小二乗推定で $M=2.08[\text{kg}]$, $B=0.604[\text{N}/(\text{m}/\text{s})]$ であった。なお、DDMのリンク重量は第1リンクー15[kg]、第2リンクー6[kg]であり、制御によって慣性項が十分下げられていることがわかる。

2.3 実験方法・データ処理

以下に、実験の構成、静止中・運動中それぞれの状態でのステイフネス測定の方法、およびデータ解析手法について説明する。

2.3.1 実験の構成

本実験では男子健常者2名(28,30歳)を被験者として行った。Fig.2.4に示すように、被験者はDDMの前に置かれた椅子に座り、肩はストラップによって椅子の背に固定さ

れる。図に示されているように、原点はDDMの1軸中心にあり、後述の実験結果はすべてこの座標系（長さの単位は[m]）で示す。被験者右前腕は、各被験者に合わせて形成したプラスチックカバーによって覆い、腕を水平面内の運動に拘束し、抗重力のための保持力の発生を防ぐため、DDM 3リンク目（このリンクは2リンク目先端で自由に回転する）に固定する。手先の位置はDDMの角度センサの値より、DDMから伝達される力は力センサにより検出される。被験者に運動をさせる場合は、手先（DDM 2リンク目先端のグリッパの中心）の目標位置をFig.2.4のA,Bの位置にLEDで示し、周囲は暗くして、被験者自身の腕の運動およびDDMの運動が見えないような状態で実験を行った。

また、実験中、手の位置計測にはDDMに取付けられているエンコーダの値を使用しているが、赤外線LEDマーカによる3次元空間での位置計測装置（OPTOTRAK）を用いて、手先とグリッパが一緒に動いていること、および外乱を与えたときと与えないときで肩の動きが一致していることを何回かの試行で確認した。




Fig. 2.4 Coordinates of DDM and a subject

2.3.2 静止中のスティフネスの計測

Fig.2.4のAからBまでの直線上のいくつかの位置で、DDMを位置制御した状態から微小変位を腕に与えた。そのときの位置と力を2[ms]毎に2[s]間測定し保存した。位置摂動を与える際のDDMへの参照位置 x_r は、(pattern A) 5次の多項式で求められる躍度最小軌道（立ち上がり時間50[ms]）で生成する方法、(pattern B) 正弦波、ステップ波、ランプ

波の組み合わせで生成する方法、の2種類を用いた。被験者には設定した位置でリラックスした状態で静止しているよう指示し、各摂動は数秒程度の間隔で、x軸正負の方向にランダムな順番で与えた。

(pattern A)の摂動の場合には、x軸正負方向に4回ずつランダムな順序で摂動を与えて平衡状態になったとき（「接線方向速度の大きさの2乗」と「力の時間変化量の2乗」がしきい値($0.002 [(m/s)^2]$, $20 [(N/s)^2]$)より低くなったときを基準とした。）、バイアスを除去した後、y方向変位量は0とし最小二乗法によりその位置でのxx方向手先ステイフネスを求めた。しきい値基準として用いる「接線方向速度の大きさ」と「力の時間変化量」はそれぞれ2次のバターースフィルタで平滑化した（カットオフ周波数は各々100[Hz], 20[Hz]）。

また、(pattern B)の摂動の場合には、x軸正負方向に40回ずつランダムな順番で摂動を与え、2.3.4に述べる方法でx方向ステイフネス係数を求めた。

2.3.3 運動中のステイフネスの計測

運動中の手先ステイフネスを摂動法によって求めるためには、外乱のあるときとないときで外乱の影響だけにより運動結果に違いが出る必要がある。Bennettら*が調べたような単関節の運動では、空間軌道は原理的に一定であり、時間パターンもリズム運動をさせることで試行毎の動作を一定にすることが比較的行いやすい。しかし平面内の2点間を通る空間軌道は無限にあり、人間はほぼ一様に運動する^{10,15)}とはいっても、試行毎にその軌道は多少ずれる。運動中に微少摂動を加えた時、運動の変動の影響を少なくし、摂動の影響を取り出すため、運動を1方向に拘束し、できるだけ様な運動データにすることを試みた。先に説明したDDMの制御により、DDMをx方向には高いインピーダンスにして拘束し、y方向には低いインピーダンスに設定した。すなわち、被験者はy軸方向にのみハンドルをスムーズに動かすことができ、それ以外の方向には自由に動かすことができない。

ハンドルを握った被験者には、合図と同時に自由に動く方向の線上に設けられたA地点からB地点（Fig.2.4を参照）まで毎回なるべく一定の時間（750[ms]程度）で手先を直線的に動かすように指示した。運動中にY方向のある位置($y = -0.20$)を通過したときX方向の位置外乱（正弦+ステップ+ランプ波の組み合わせ(pattern B)）を与え、手先で発生されるx方向の力を測定した。この動作を1セッション中に数秒間隔で120回（正負零

で各々40回づつ) ランダムな順序で行った。データは、ハンドルがy方向の位置 ($y = 0.15$)を過ぎたらサンプリングを開始し、2[ms]間隔で1[s]間記録した。スティフネスは次に示す方法で推定した。

2.3.4 スティフネスの計算

水平面内で動作する2リンクと考える腕を、次式のように2次の非線形微分方程式で表す。

$$\Phi(\ddot{x}, \dot{x}, x, \kappa) = F_{ext} \quad (2-5)$$

ここで、 x は手先の位置ベクトル ($x = [x, y]^T = \text{DDMグリッパの位置ベクトル}$)、 F_{ext} はDDMによって与えられる外力、 κ は脳運動中枢からの運動指令を表す。この状態に単に位置の摂動だけを与えることができれば、スティフネスを計算することができるが、加速度、速度の影響が無くなるまでには時間を必要とするためスティフネスの時間変化を観察することができない。加速度、速度の影響を考慮するため、式(2-6)で表される変分方程式の係数行列を求めることを考える。

$$\frac{\partial \Phi}{\partial \ddot{x}} \delta \ddot{x} + \frac{\partial \Phi}{\partial \dot{x}} \delta \dot{x} + \frac{\partial \Phi}{\partial x} \delta x = \delta F_{ext} \quad (2-6)$$

この式を時変線形系と考え、次の式で置き換える。

$$\begin{bmatrix} M_{xx}(t) & M_{xy}(t) \\ M_{yx}(t) & M_{yy}(t) \end{bmatrix} \delta \ddot{x} + \begin{bmatrix} B_{xx}(t) & B_{xy}(t) \\ B_{yx}(t) & B_{yy}(t) \end{bmatrix} \delta \dot{x} + \begin{bmatrix} K_{xx}(t) & K_{xy}(t) \\ K_{yx}(t) & K_{yy}(t) \end{bmatrix} \delta x = \delta F_{ext} \quad (2-7)$$

静止中、運動中共、この式の左辺第1, 2, 3項目の係数行列を慣性、粘性、剛性(スティフネス)と呼ぶ。この式を利用するためには、摂動を与えたときの状態から摂動を与えないときの状態を引くことが必要となる。運動中の各係数を計算するためには、同じ運動で摂動を与えたときと与えないときのデータが必要である。本実験では、x方向の運動中と静止中のスティフネスのみを比較対象としたため、x方向の摂動だけを用い、また各運動毎の変動を押さえて摂動の影響を取り出すために、(1)摂動を与えないとき、(2)x軸正方向に摂動を与えたとき、(3)x軸負方向に摂動を与えたとき、のデータをそれぞれ平均化した。そして、各時刻の前後150[ms]づつ(2[ms]おきのサンプリング周期の

ため、前後75点のデータ)の時間窓に入るデータを使用し、時間を追って各係数を最小二乗推定した(付録2-C参照)。また、式(2-7)の加速度、速度、位置、力のデータは全て2次のバターワースフィルタ(cut off 50[Hz])で滑らかにしている。

2.4 実験結果

2.4.1 摂動の種類に依存したステイフネス

ここでは、摂動を用いたステイフネスの計測が、摂動の種類により変化することを被験者Bのデータを用いて示す。Fig.2.5 aは、2.4.1で説明した摂動pattern Aの場合の、x方向の位置と力の変化分の時間変化を示す。この摂動の場合には、位置を滑らかに立ち上げているにも関わらず、立ち上がりより200[ms]程度は腕の振動の影響により反力が振動的である。2.3.2に述べた方法で平衡状態になったときの位置と力の関係から計算したxx成分のステイフネスの値は $K_{xx}=330.4$ [N/m]であった。

Fig.2.5 bは摂動がpattern Bの場合のx方向の位置と力の変化分の時間変化、および時間を追って推定されたxx成分のステイフネスを示す。この場合、推定開始(0.15[s])から推定終了(0.85[s])までのステイフネスの平均値は、 $K_{xx}=155.2$ [N/m]であった。ステイフネスの平均値の比較より明らかなようにpattern Bで摂動を与えたときの方が推定されたステイフネスは小さい。Fig.2.5のaとbを比較すると、与えている移動量としては両ケースとも5[mm]程度であるため、移動量の差によって生ずる違いではなく、摂動の種類によって生ずる違いであることがわかる。この差が発生する原因は2.6で考察するように腕の反射系などの特性によるものと考えられる。このことから、静止中と運動中のステイフネスを比較するときは、条件の1つとして、与える摂動を等しくしなければならないことが判った。

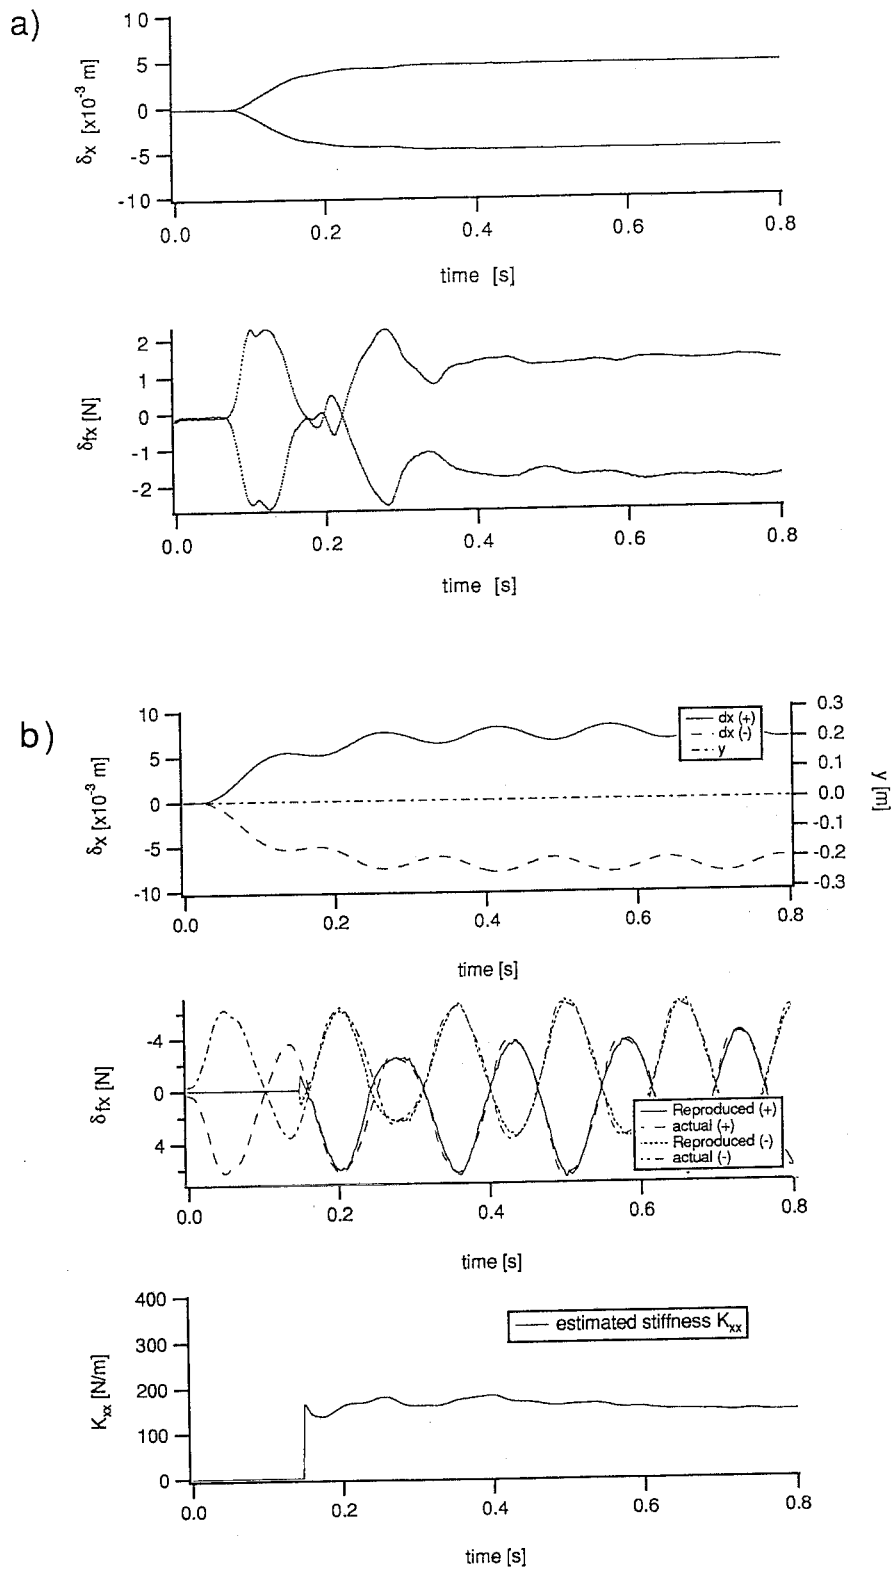


Fig. 2.5 Difference in static stiffness values of subject B due to the perturbation patterns in posture control. a) perturbation pattern A, b) perturbation pattern B

2.4.2 静止中と運動中のステイフネスの比較

次に、静止中と運動中のステイフネスを比較する。摂動は、x方向の力に關与する6つのパラメータ ($M_{xx}, M_{yy}, B_{xx}, B_{yy}, K_{xx}, K_{yy}$) を推定する必要から、pattern Bを使用している。Fig.2.6 (A) は被験者Aの場合のFig.2.6 (B) は被験者Bの場合の実験結果を示す。両図において (a)は 摂動を与えたことによるx方向の位置の変化とy方向位置 (各々平均値) を、(b)は、静止中、運動中のデータ、2リンクモデルから推定された M_{xx} を、(c)は推定された粘性 B_{xx} 、(d)は推定されたステイフネス (弾性) K_{xx} 、(e)は計測した F_{extx} と、推定されたパラメータと軌道を使って再構成した \hat{F}_{extx} の比較である。(b)の四角の点は、運動を行った軌道途中の4つの位置における静止時のデータで推定した M_{xx} であり、実線は運動中のデータで推定した M_{xx} 、点線は2リンクのモデルを使って運動の際の軌道を使って計算した M_{xx} であるが、それぞれの値はほぼ等しい。また(d)から判るように、求められた係数と軌道によって力を再構成した場合、再構成波形がある程度測定波形と一致しており、これらのことは、この推定が適切に行われていることを示している。

さて、推定されたステイフネスであるが、被験者Aにおいては運動中を通じて静止中の場合と同程度の値になっている。また被験者Bでは、運動中の方が静止中よりも低い値になっている。これらの結果より、個人差はあるが、運動中のステイフネスが静止中に比べて、同程度かあるいは小さくなっていると考えられる。この結果がどの程度一般性を持つかを確認するためには、より推定精度を上げ、多くの被験者を対象に計測する必要がある。

2.5 考察

2.5.1 摂動パターンによるステイフネスの変化の理由

実験結果(2.4.1)に示したように、静止中のステイフネス計測においても、ステイフネスの値は摂動のパターンによって大きく異なってしまう。この1つの理由としては、フィードバック反射系の状態が摂動の種類によって変化することが考えられる。ここで示したような摂動を与えて、それに反応する力を計測しステイフネスを観察する場合には、拮抗する筋肉の受動的な張力と長さの関係以外に運動細胞(α -MN)の活動状態が影響する^{41,12)}。また、生理学・解剖学的研究で明らかになったように、筋肉には3種類のフィードバック信号(GIa, GIIa, GIb)がある。GIa信号は、その信号を検出した筋紡錘を含む筋肉 (同名筋) やそれと拮抗する筋肉の運動細胞(α -MN)に影響を与える⁴²⁾。

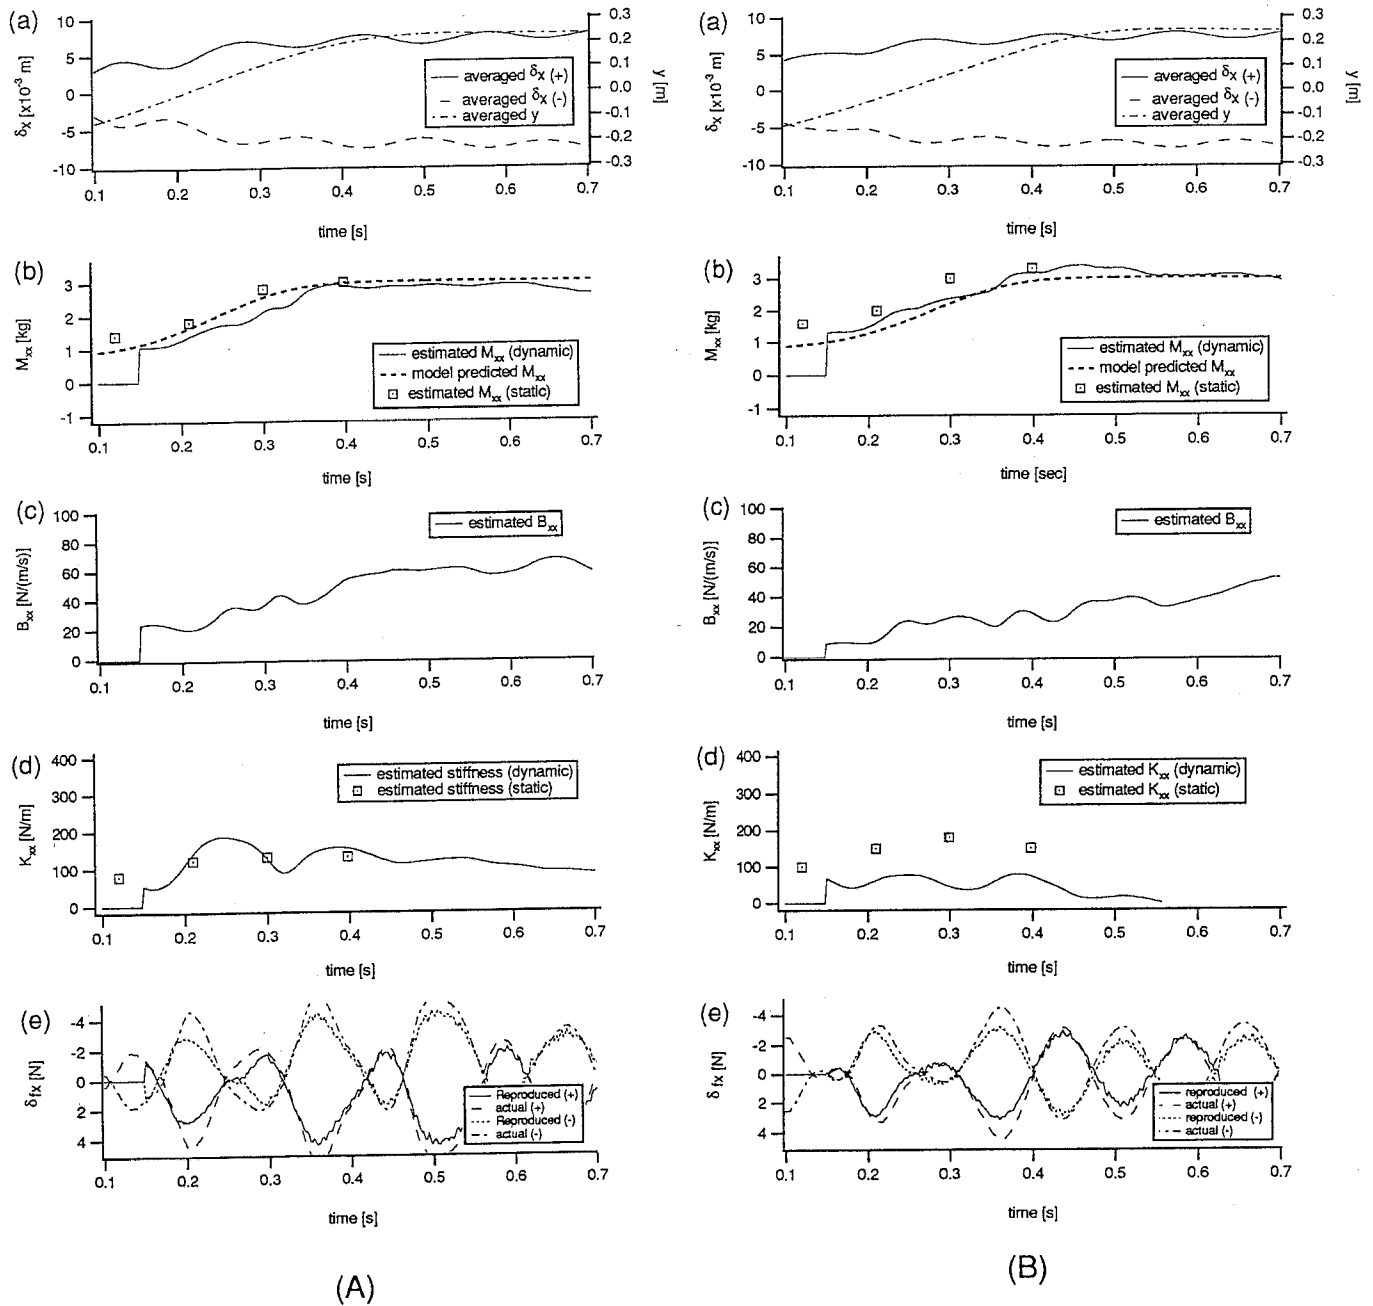


Fig. 2.6 Estimated mass, viscosity and stiffness of xx-directional parameters during movement and those during static posture control. A) subject A, B) subject B

そのフィードバックの状態は、運動細胞(α -MN)の活動状態や拮抗筋のG1aのフィードバック信号の影響を受け⁴²⁾、大きく変化する。これらの要因により、摂動の変化がフィードバック反射系の状態を変え、検出されるスティフネスの状態が変化したと考えられる。従来計測されたスティフネスの値の大きな違い^{34,38,36,39)}は、被験者による個人差ばかりでなくこのような摂動の違いにより生じたのではないかと考えられる。いずれにしろ、静止中と運動中の上位中枢からの運動指令の違いによるスティフネスの変化の影響を観察するためには、同様の摂動パターンを適用した結果を比較する必要があることが示された。

2.5.2 運動中のスティフネスが上昇しない理由

さて、同じ摂動パターンを与えた実験結果から示されるように、運動中のスティフネスは静止中に比べて上昇していない。これは主に上位中枢より反射系の状態が変えられているためであろうと考えられる。近年運動中のG1aフィードバックゲインの観察が行われ、随意的な運動をしている最中には運動細胞を活性化するG1a信号のゲインが下がってしまう、すなわち反射によって生ずるスティフネスの上昇を押さえるメカニズムがあることが発見された^{43,44)}。これは、運動細胞に入るG1aフィードバック信号が上位中枢から抑制されていると考えられており、反射による不随意性の運動を押さえ、上位中枢からの司令を優先して思いどおりの動きをするためには必要なことであろうと思われる。またBennet (私信) は、静止中のスティフネスの方が運動中のそれよりも高い原因として、short range stiffnessと呼ばれる筋肉を少し伸ばしたときに見られるスティフネスが上昇する現象の存在や運動中と静止中に出す力の差などを挙げている。

2.5.2 内部モデルを必要としない仮想軌道制御仮説に対する反論

2.4節で示した実験結果やスティフネスを上昇させる主な原因である反射系のゲイン低下というメカニズムを考えても、脊髓・脳幹レベルでの反射系で高いスティフネスが実現されている見込みは少なく、計測した運動中のスティフネスはFlashがシミュレーションで使用した値の5分の1以下になっている(付録2-B参照)。このため、主働筋と拮抗筋によって得られる平衡位置はその時点での位置から遠くはなれていることになる。片山ら³²⁾はシミュレーションで、運動中のスティフネスがFlashが用いたような高い

値にならない場合 (K_{xx} 67-107[N/m]) は、直線軌道を描くときの平衡軌道は曲がりくねったものになってしまうことを示した。「仮想軌道仮説」の主張点の1つは、中枢神経系は制御対象のダイナミクスを考慮せずに軌道計画を行えることであった¹¹⁾。しかし、ステイフネスが低い場合に目標軌道どうり動かすためには、制御対象のダイナミクスを考慮して複雑な仮想軌道を計画しなければならない。このことは、中枢神経系は「ダイナミクスを考慮せずに計画する仮想軌道」というよりはむしろ「制御対象の内部モデル」を積極的に利用して運動司令を出力していると説明するほうがより適切であることを示唆している。

2.6 まとめ

運動と垂直方向に摂動を与えることにより、多関節運動中の手先ステイフネスを調べた。ここで報告した実験では、機器の精度や制御性の限界のためにステイフネス行列の xx 成分だけを考察の対象とした。運動中と静止中のステイフネスを比較した結果、運動中のステイフネスは静止中と同程度あるいは低くなることが判った。単関節での運動中のステイフネス計測結果³⁴⁾をあわせて考えると、運動中の手先ステイフネス行列の要素は全て小さくなっていることが予想され、その場合運動中の平衡軌道（主働・拮抗筋の釣り合い位置）は実際の軌道から大きくはなれていることになる。このことは、中枢神経系は筋骨格系に平衡位置を司令するという「仮想軌道仮説」に疑問を投げかけるものである。低ステイフネスの場合、目標どうりに制御対象を動かすためには、制御対象の特性に関する知識が必要となり、中枢神経系は、制御対象である腕の内部モデル（逆モデル）を持ち、目標とする運動を行うための運動司令の生成にそれを利用して制御を行っていると考えられる。

第3章

神経回路モデルを用いた 「フィードバック誤差学習」による 閉ループ系の学習制御

本章では、フィードバック学習制御系における内部モデル獲得による学習制御スキームを提案する。具体的には、川入らの提案した⁹⁾「フィードバック誤差学習法」を、学習型フィードバック制御に拡張した学習方法である「逆モデル学習」と「非線形レギュレータ学習」について説明する。そして学習の有効性を、不安定非線形制御対象である倒立振り子制御、2リンクマニピュレータの学習型インピーダンス制御のシミュレーションにより示す。学習の収束性についての理論的考察は付録で述べる。

3.1 はじめに

第2章で、生体系の運動において制御対象の内部モデルによる制御が行われている可能性についての考察を行った。本章では、そのような制御対象の内部モデルが、制御性の改善に対してどのような役割をするのか、いかなるメカニズムによって獲得されるのか、について一般的な制御モデルの立場から考察する。

従来、制御系における適応学習は、適応制御理論に基づいた方法、アダプティブプロダクションシステムやファジィ、神経回路モデルによるコントローラを使用する方法などがある。

適応制御理論では、線形系に対して理論的構築がなされ、線形であると見なせる制御対象に対して多く適用され、その有効性も確認されてきた。非線形性の強いロボットなどの対象に対しては、Dubouskyら⁴⁵⁾やSlotineら⁴⁶⁾の研究がある。しかし、前者は局所的に線形化した系に対して線形コントローラのゲインを調整するにすぎず、遠心力・コリオリ力などの非線形性を持った制御対象を高速で動かす場合には適応速度が追い付かなくなるという問題が生ずる。また後者の方法は取り扱われている制御対象の変動パラメータが線形に表れる特性を利用しており、制御対象に未知の非線形要素が含まれる場合には使用できない。例えば、ロボットには予めその構造より知ることのできる遠心力・コリオリ力・重力などの非線形性の他にアンプ・アクチュエータ・伝達機構などの既知で

はない非線形性が存在するのでSlotineの方法はそのままでは使うことができない場合がある⁴⁷⁾。別の見方をすれば、両者の適応制御方法における問題点とも、モデル化に関する知識が不十分である制御対象を強引に線形適応系に落とし込んでいるために生じているとも言えよう。また、軌道追従性を狙った適応制御方法は、パラメータの収束と軌道の収束を満たすよう1つのリアプノフ関数を構成しパラメータ調整則を導いているため^{46,69)}、軌道に誤差が生じたときパラメータも一度理想値からずれ、軌道の収束とともに再度理想値に収束することになる。外乱などにより軌道がしばしばはずれる場合、その度に適応制御器のパラメータも変化するため、適応系をなるべく高速に作動させる必要がある。

一方、神経回路モデルを用いた学習問題では教師あり学習が多く行われているが^{48,49,50)}、ロボットやプラントの制御器を学習によって獲得する場合は、学習すべき制御信号の理想値（教師）が与えられない場合がほとんどである⁵¹⁾。このような問題に対する解決策の1つは、Bartoら⁵²⁾によって提案されたACE (Adaptive Critic Element), ASE (Associative Search Element)の考え方で、制御器の過去の動作履歴を記憶し、ある時点での失敗から記憶している過去の動作に対し修正を加えるというものである。Bartoら⁵²⁾は、この学習方法を倒立振り子制御に適用し学習の有効性を示した。この学習は”誤差の方向”を与えない点で他の学習と異なり、人間の学習との類似点もあるが、その学習によってどの程度制御性が向上するのかが定量的に判りにくく、また学習による収束性についてもまだ理論的な説明がなされていない。

別の考え方としては、Fig. 3.1(a)に示すように、制御対象の入力と出力の関係を逆転させて神経回路モデルに与えて制御対象の逆写像を学習させた後、その神経回路モデルを制御器としてフィードフォワード制御を行う「直接逆モデリング」と呼ばれる方法がある。この方法は、多くの研究者によって適用例が示された^{53,54,55,56)}が、制御対象の入出力の関係が「多対1」になる（すなわち冗長性を持つ）場合には学習により逆写像を得ることができないという問題点を持つ¹⁷⁾。

制御対象に対して目標とする動作（出力の目標値）を与える場合、制御対象の出力誤差から、その制御対象への入力誤差を導き出す手段として、Jordan⁵⁷⁾はFig. 3.1(b)に示す「順逆モデリング」を提案した。これは制御対象の出力誤差を学習した順モデルを逆伝播(back propagation)することにより制御対象への入力誤差（すなわち制御器の出力の誤差）に変換する方法である。同様の学習則は、Narendraら⁵⁸⁾によっても提案されているが、この学習スキームでは、制御対象の順モデルを学習しなければならない点、獲得した

順モデルを逆伝搬して"出力誤差"を"入力誤差"に変換しなければならない点が複雑であり, また生体系で行われている学習のモデルとは言い難いことが指摘されている¹⁷⁾.

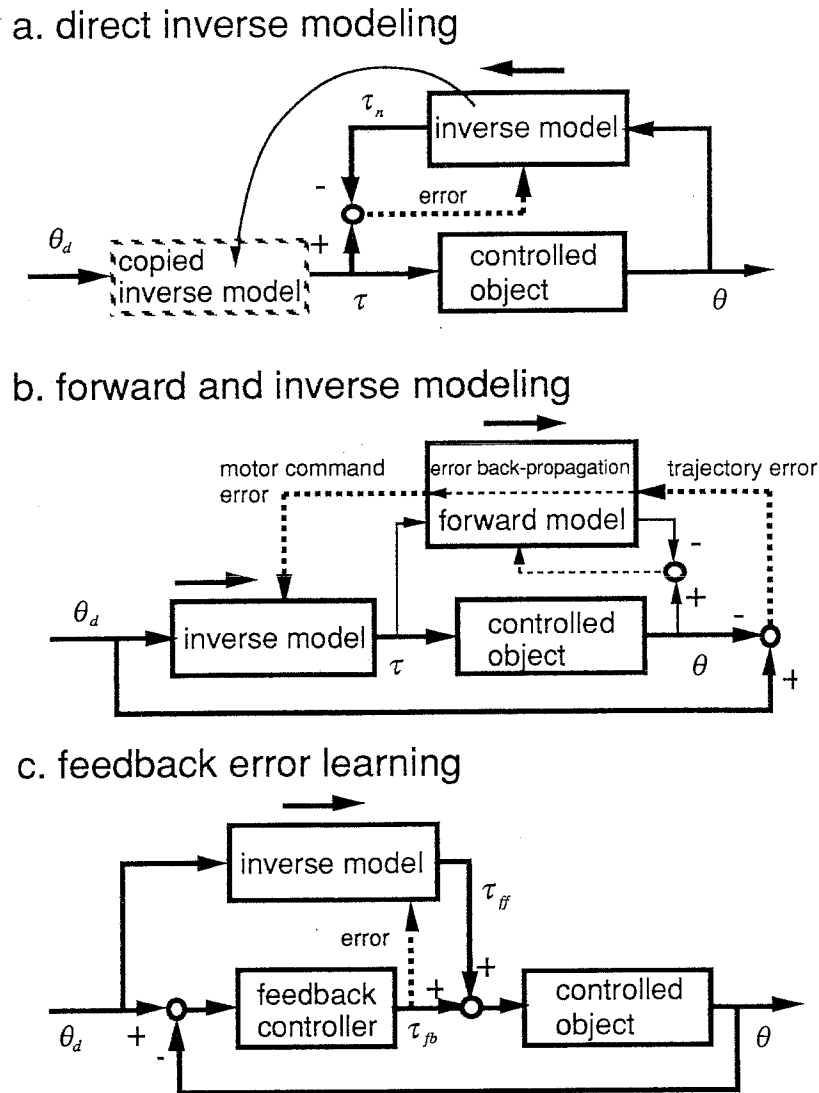


Fig. 3.1 Three computational schemes for learning inverse dynamics model of a controlled object which acts as a feedforward controller.

さて, これらの制御のための逆モデル学習手法に対し, 1.2.2に述べたように川人ら⁹⁾はFig.3.1(c) に示すような「フィードバック誤差学習」という手法を提案した. これは online 学習法であり, 始めはフィードバック制御器でぎこちなく制御されていたものを, 運動をしながら徐々にフィードフォワード制御器に逆モデルを獲得し, 運動を正確なものにしていく方法である. 学習の進行と共にフィードバック制御器の出力は小さくなってゆく. この学習は, 生体系で行われている学習メカニズムに近く, また実際の制御へ

の応用例も多い^{19,20,21,22}。しかしブロック図からもわかるように、Fig.3.1 (a) (b)のスキーム同様に(c)も、フィードバック制御性を改善することは出来ず、生体系における姿勢制御や歩行制御などの多くのフィードバック制御の改善を説明することは出来ない。

そこで本章では、フィードバック制御系の制御性を改善する学習制御スキームを提案する。具体的には、川人らが提案した学習型フィードフォワード制御を実現するための「フィードバック誤差学習法」を、学習型フィードバック制御に拡張した方法である「逆モデル学習」と「非線形レギュレータ学習」について説明する。これらの学習スキームでは、神経回路モデルで構成した非線形フィードバック制御器に対して、規範モデルの役割をする従来型のフィードバック制御器（以下CFC (Conventional Feedback Controller)と呼ぶ）の出力を誤差信号として与える。学習が完了した際には、神経回路モデルが制御対象の内部モデルを獲得し、制御対象の出力が規範モデルで規定される応答に従うというものである。不安定非線形対象である倒立振り子、2リンクマニピュレータの学習インピーダンス制御のシミュレーションにより、学習の有効性を3.3節で確認する。また3.4節では、提案する2つのスキームの類似点・相違点を明確にし、さらに別のグループから提案されている神経回路モデルによるフィードバック制御手法との関連性および従来提案された固定ゲイン式のインピーダンス制御手法との関係について詳細に検討する。

3.2 学習型非線形フィードバック制御

以下に、「フィードバック誤差学習を利用したフィードバック制御器の学習」を2つの学習スキームに分けて提案する。1つめのスキームは、神経回路モデルが制御対象の逆モデルを獲得することから、「逆モデル学習」と呼ぶ。このスキームでは、神経回路モデルの入力として制御対象の現在の状態を表わす位置・速度・加速度の計測値を使用し、学習のための誤差信号としてフィードバックコントローラからの出力と制御対象に入力される外部入力の和を用いる。もう1つは、学習によって神経回路モデルが制御対象の加速度依存項（慣性項）以外の非線形性を補償し規範モデルで規定される目標応答をするようになることから、「非線形レギュレータ学習」と呼ぶ。このスキームでは、神経回路モデルへの入力として、加速度、速度、位置の目標値および制御対象の速度、位置の計測値を用いる。各々の学習の収束性についての理論的考察は、付録3-B, 3-Cで述べる。

3.2.1 逆モデル学習

制御対象への入力を τ ，線形フィードバックコントローラからの出力を τ_c ，神経回路モデルからの出力を τ_n として式(3-1), (3-2), (3-3)で表す。

$$f(\ddot{\theta}, \dot{\theta}, \theta) = \tau \quad (3-1)$$

$$\tau_c = K_2(\ddot{\theta}_r - \ddot{\theta}) + K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta) \quad (3-2)$$

$$\tau_n = \Phi(\ddot{\theta}, \dot{\theta}, \theta, w) \quad (3-3)$$

ここで， f は未知の非線形性を含む最小位相制御対象のダイナミクス， $\ddot{\theta}, \dot{\theta}, \theta$ は制御対象の加速度，速度，位置ベクトルの計測値， $\ddot{\theta}_r, \dot{\theta}_r, \theta_r$ は各々の参照入力ベクトル*， K_2, K_1, K_0 は加速度，速度，位置の各誤差のフィードバックゲインマトリックス， Φ は神経回路モデルによって実現される関数， w は神経回路モデルの内部パラメータ（以後，「シナプス荷重」と呼ぶことがある。）を代表して表したものである。

Φ を実現する神経回路モデルは，内部パラメータを調整することで出力の誤差ベクトルを減少するメカニズムを持つもの，例えば代表的な神経回路モデルであるMLP (Multi Layer Perceptron)³⁾，CMAC (Cerebellar Model Articulator Controller)⁵⁹⁾，associative content addressable memory⁶⁰⁾，MBR (Memory Based Reasoning)⁶¹⁾，RBF (Radial Basis Function)⁶²⁾などにより構成するものとする。神経回路モデル内部パラメータの調整はここで提案している学習スキームとは独立に考えることができ，具体例として次節に示すシミュレーションで用いたMLPの学習アルゴリズムを付録3-Aに示す。使用する神経回路モデルの最適な構造やサイズは学習すべき目的関数に依存し，関数近似能力や汎化性能の問題として一般的に議論される。この問題は本論文の範囲を越えるため，ここでは Φ を実現する神経回路モデルが，シナプス荷重 w を最適値 \hat{w} に取ることで目的とする関数を必要な精度で実現できる，すなわち，

$$f(\ddot{\theta}, \dot{\theta}, \theta) \cong \Phi(\ddot{\theta}, \dot{\theta}, \theta, \hat{w}) \quad (3-4)$$

が実現できるという条件を満たすものと仮定する。この関数近似可能性の仮定は，MLPやRBFについては具体的に議論されている^{63,64,65)}。

さて，上式(3-1), (3-2), (3-3)で表される要素を用い Fig. 3.2 のような系を構成すると，

*本文中，システムへの指令値を「参照入力(reference input)」，学習後に得るべき制御対象の出力値を「目標値(desired output)」と呼ぶ。

τ_{ext} を外部から制御対象への入力として、

$$\tau = \tau_n + \tau_c + \tau_{ext} \quad (3-5)$$

と表せる。

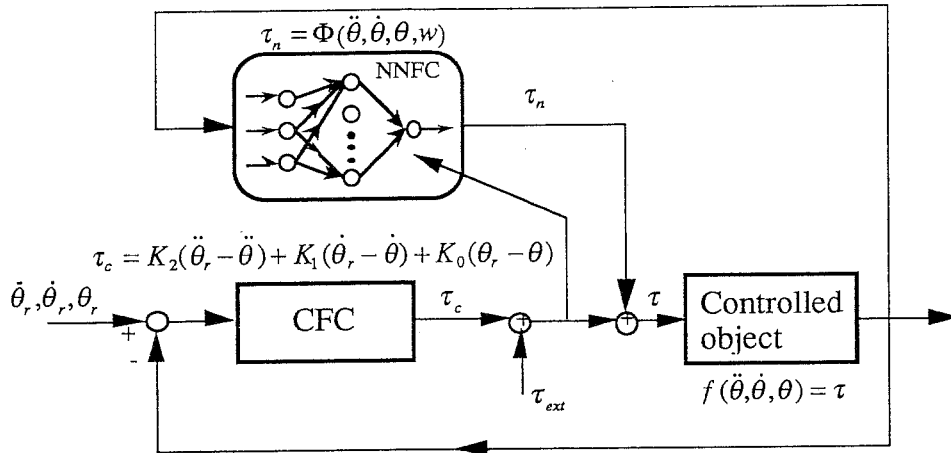


Fig. 3.2 Block diagram of inverse dynamics model learning (IDML).

ここで、対象のダイナミクスと神経回路モデルの出力の差を τ_{imag} とおく。

$$\tau_{imag} = \tau - \tau_n = \tau_c + \tau_{ext} \quad (3-6)$$

これは神経回路モデルが対象の完全な逆モデルを与えられないために生ずる入力誤差とみることができ、式(3-7)の様にCFC(Conventional feedback controller)で規定される仮想的なダイナミカルシステムに対する入力 τ_{ext} に余分な擾乱 τ_{imag} が加わっているように表せる。

$$K_2(\ddot{\theta} - \ddot{\theta}_r) + K_1(\dot{\theta} - \dot{\theta}_r) + K_0(\theta - \theta_r) = \tau_{ext} - \tau_{imag} \quad (3-7)$$

さて、Fig.3.2で示す様な「フィードバック誤差学習」を行うとき、学習則は次のように書ける。

$$\frac{dw}{dt} = \eta \left(\frac{\partial \Phi}{\partial w} \right)^T (\tau_c + \tau_{ext}) = \eta \left(\frac{\partial \Phi}{\partial w} \right)^T \tau_{imag} \quad (3-8)$$

ここで、 η は正定行列で学習速度を決める係数である。

式(3-8)の学習則を,

条件1 : 学習速度係数 η は非常に小さな固有値を持つ正定行列.

条件2 : τ_{ext} と $\dot{\theta}_r$ は十分なめらか(少なくとも1階微分可能)で, かつ確率過程として見たとき, 強混合・強定常過程である.

条件3 : 従来型のフィードバック制御器(CFC)は $\tau_{ext} = 0$ のとき, 常に θ を θ_r に漸近的に収束させる機能を有する.

という条件のもとで用いる. τ_{imag} が徐々に減少し, $\tau_{imag} = 0$ が平衡点となるならば, 式(3-6)より $\tau_n = \tau$ となり, 神経回路モデルには制御対象の近似逆ダイナミクスモデルが形成され, 結局フィードバック制御器の出力 τ_c と外部入力 τ_{ext} によって規定される次式,

$$K_2(\ddot{\theta} - \ddot{\theta}_r) + K_1(\dot{\theta} - \dot{\theta}_r) + K_0(\theta - \theta_r) \equiv \tau_{ext} \quad (3-9)$$

に従う応答を得る. すなわちこの学習では, $\tau_c + \tau_{ext} = 0$ が学習後の応答を規定しており, 制御理論では, モデル規範型適応制御の部類に属すると考えられる. 以下では, 式(3-9)の様な学習後の応答を規定するものを「規範モデル (reference model)」と呼び, $\tau_{imag} = 0$ の時に実現される応答をことを「目標応答 (desired response / desired output)」と呼ぶ. この学習の有効性は3.3.1でシミュレーションにより確認し, 収束性の理論的考察は付録3-Bに確率空間で検討する.

さて, 上で説明した「逆モデル学習」は, 規範モデルが制御対象の出力と同じ座標系の上で設定されている. 多リンクマニピュレータ等では, インピーダンス制御⁴⁰⁾やハイブリット制御⁶⁶⁾でも知られるように, リンクの関節座標系ではなく, 作業空間での座標系(デカルト座標系)で動きを設定することがしばしば必要とされる. そこで次に, 「逆モデル学習」をマニピュレータ制御に応用するため, 作業空間で規範モデルを設定する場合の式を導出し, それが「学習型インピーダンス制御」になることを示す.

一般の多関節マニピュレータの運動方程式は次のように表される.

$$R(\theta)\ddot{\theta} + N(\theta, \dot{\theta}) = \tau \quad (3-10)$$

ここで, R は加速度係数行列(慣性行列), N はコリオリ・遠心力・摩擦など速度・位置に依存する項(行列)であり, それぞれ非線形要素を含む. そして学習後に要求する

応答すなわち参照モデルを作業座標系で設定するために、従来型のフィードバック制御器(CFC)を次式のように設定する。

$$F_c = M\ddot{x}_e + B\dot{x}_e + Kx_e \quad (3-11)$$

ここで、 $x_e = x_r - x$ で、 M, B, K はインピーダンス制御パラメータである仮想慣性、粘性、弾性を表す。ただし、 M, B, K は常にシステムの漸近安定性を補償するフィードバックコントローラの役割を満たすよう設定するものとする。神経回路モデルを上記の逆モデル学習スキームと同様に式(3-3)で表し、マニピュレータ先端に加わる作業座標系での外力を F_{ext} として、Fig. 3.3 の様に学習系を構成する。

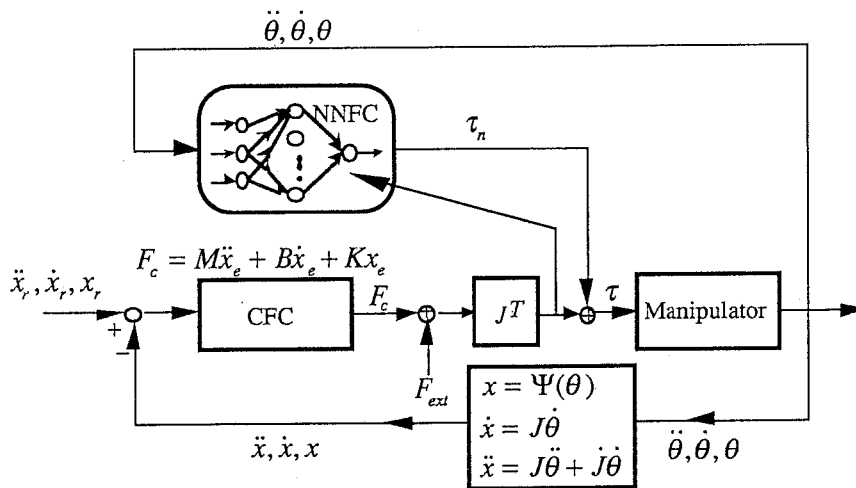


Fig. 3.3 Block diagram of learning impedance control.

Fig. 3.3 に示すように神経回路モデルNNFCに誤差信号 $J^T(F_c + F_{ext})$ を与え学習を行ったとき、前述の関節座標系での逆モデル学習と同様、NNFCが制御対象の逆ダイナミクスモデルを獲得した場合、

$$\begin{aligned} \tau &= \tau_n + J^T(F_c + F_{ext}) \\ &\cong R(\theta)\ddot{\theta} + N(\theta, \dot{\theta}) + J^T(M(\ddot{x}_r - \ddot{x}) + B(\dot{x}_r - \dot{x}) + K(x_r - x) + F_{ext}) \end{aligned} \quad (3-12)$$

となる。その結果マニピュレータ先端の軌道は、規範モデルである次式、

$$M(\ddot{x} - \ddot{x}_r) + B(\dot{x} - \dot{x}_r) + K(x - x_r) \equiv F_{ext} \quad (3-13)$$

に従って動作することになる。

すなわち、作業座標系で規範モデルが設定された場合でも、関節座標系の場合と同様に逆モデル学習を行うスキームが考えられ、上で述べた学習が完了した際には、応答の規範モデルを変化させることにより、外部から働く力に対する応答性を自由に制御することが可能な「インピーダンス制御」を実現する。また、学習によって神経回路モデル (NNFC) が獲得するものは制御対象であるマニピュレータの逆ダイナミクスであるため、NNFCはマニピュレータのダイナミクスが変化しない限り再学習の必要はなく、学習中・学習後とも、CFC (Conventional Feedback Controller) に設定する目標インピーダンス (規範モデル) は、安定性が保たれる範囲内で自由に設定値を変えることが出来る。この学習の有効性は、3.3.3にシミュレーションで確認する。

3.2.2 非線形レギュレータ学習

この学習では、NNFCの入力として制御対象の加速度の計測値 $\ddot{\theta}$ は使用せず、参照軌道 $\ddot{\theta}_r, \dot{\theta}_r, \theta_r$ と速度・位置の計測値 $\dot{\theta}, \theta$ を NNFC の入力とする。以下に、この学習スキームと学習の結果得られる応答について説明する。

制御対象のダイナミクスを加速度に依存する項とそれ以外の項に分けて次式のように表す。

$$R(\theta)\ddot{\theta} + N(\theta, \dot{\theta}) = \tau \quad (3-14)$$

ここで、 R, N は未知の非線形項を含む制御対象のダイナミクスによって決まる項であり、多くのロボットなどのダイナミクスは上式のように表せる。CFCは3.2.1で用いたものと同様、式(3-2)の様に設定する。また、NNFCは参照軌道 $\ddot{\theta}_r, \dot{\theta}_r, \theta_r$ と、位置と速度の誤差 $\theta_r - \theta, \dot{\theta}_r - \dot{\theta}$ を入力としかつ内部にシナプス荷重 w (内部パラメータ) があるため次のように表せる。

$$\tau_n = \Omega(\ddot{\theta}_r, \dot{\theta}_r, \theta_r, \dot{\theta}, -\dot{\theta}, \theta_r - \theta, w) = \Phi(\ddot{\theta}_r, \dot{\theta}_r, \theta_r, \dot{\theta}, \theta, w) \quad (3-15)$$

これらを用いて Fig. 3.4 に示す系を構成すると、

$$\tau = \tau_n + \tau_c$$

$$\Leftrightarrow (R(\theta) + K_2)(\ddot{\theta}_r - \ddot{\theta}) + K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta) + \Phi - N(\theta, \dot{\theta}) - R(\theta)\ddot{\theta} = 0 \quad (3-16)$$

となる。

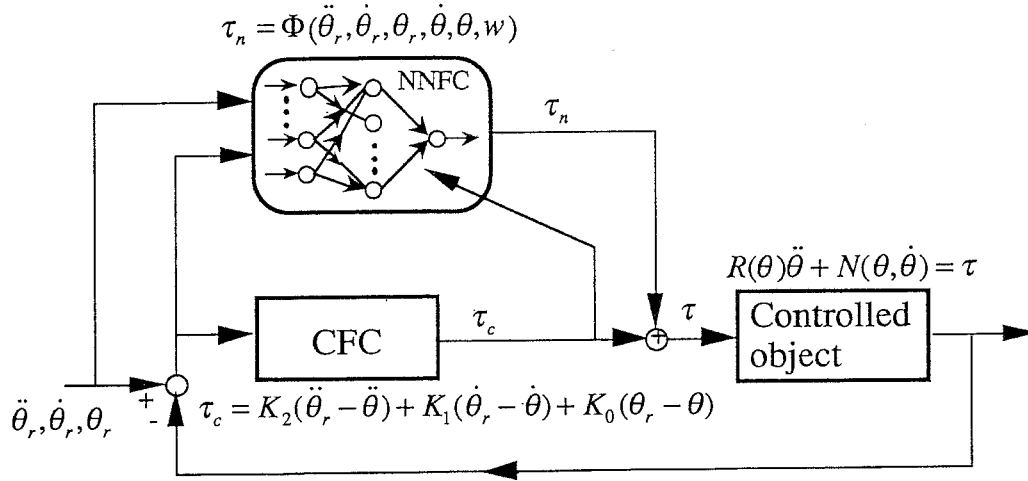


Fig. 3.4 Block diagram of nonlinear regulator learning (NRL).

ここで、NNFCで実現する関数 Φ が、

$$\Phi \equiv \Phi_d = N(\theta, \dot{\theta}) + R(\theta)\ddot{\theta} + R(\theta)K_2^{-1}(K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta)) \quad (3-17)$$

となるとき、式(3-16)より

$$\begin{aligned} & (R(\theta) + K_2)(\ddot{\theta}_r - \ddot{\theta}) + K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta) + R(\theta)K_2^{-1}(K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta)) \equiv 0 \\ \Leftrightarrow & (I + R(\theta)K_2^{-1})(K_2(\ddot{\theta}_r - \ddot{\theta}) + K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta)) \equiv 0 \end{aligned} \quad (3-18)$$

となる。 $I + R(\theta)K_2^{-1} \neq 0$ であるように K_2 を設定すれば、 θ の応答は次式に従う。

$$K_2(\ddot{\theta} - \ddot{\theta}_r) + K_1(\dot{\theta} - \dot{\theta}_r) + K_0(\theta - \theta_r) \equiv 0 \quad (3-19)$$

言い替えると、NNFCに式(3-17)で表わされる関数が実現されれば、実際の出力 θ はCFC

に設定された規範モデルにしたがって、目標軌道 θ_r に収束することになる。

Fig. 3.4 中に示す式(3-20)で表されるフィードバック誤差学習，すなわちCFCからの出力をNNFCの学習のための誤差信号とする学習を行うと，学習によってNNFCは式(3-17)で表わされる関数を近似的に獲得し，学習後には式(3-19)に従う応答が得られる。

$$\frac{dw}{dt} = \eta \left(\frac{\partial \Phi}{\partial w} \right)^T \tau_c \quad (3-20)$$

この学習の収束性の考察は付録3-Cに確率空間で議論するが，直観的には次のように解釈できる。非線形レギュレータ学習の場合は，加速度の計測値をNNFCの入力として使用しないことで制御対象の慣性項がNNFCによってフィードバック補償されることがない。そのため，逆に慣性項の非線形性によって速度・位置の項が補正されて規範モデルで規定される目標応答が得られるよう学習が行われるということである。この学習では，NNFCに獲得すべき目的関数 Φ_d に K_2, K_1, K_0 が含まれるため，それらのパラメータを変更する際にはNNFCの再学習が必要となる。しかし，目標加速度 $\ddot{\theta}_r$ の代わりに，

$$\ddot{\theta}_r^* = \ddot{\theta}_r + K_2^{-1} (K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta)) \quad (3-21)$$

をNNFCの入力とすることで，NNFCが獲得すべきもの（目的関数）は，式(3-17)の代わりに，

$$\Phi_d = N(\theta, \dot{\theta}) + R(\theta) \ddot{\theta}_r^* \quad (3-22)$$

と表わされ，NNFCに獲得する関数がパラメータの変更に依存しない，すなわち再学習の必要のない学習系も構成可能である。非線形レギュレータ学習の有効性を確認するシミュレーション結果は3.3.2に示す。

3.3 シミュレーション結果

本節では，前節で述べた学習スキームの有効性を示すため，幾つかの制御対象に適用したときのシミュレーションの結果を示す。逆モデル学習と非線形レギュレータ学習を倒立振子制御に適用した例および，逆モデル学習の応用である「学習型インピーダンス制御」を2リンクマニピュレータに適用した例を示す。

すべてのシミュレーションは4次のRunge-Kutta法（倒立振子シミュレーションでは $\Delta t = 2 \times 10^{-5}$ [sec]，マニピュレータシミュレーションでは $\Delta t = 2 \times 10^{-4}$ [sec]）を使用した。

3.3.1 逆モデル学習による倒立振り子制御

ここでは簡単のために、倒立振り子のダイナミクスのみを考慮し台車のダイナミクスを無視するため、倒立振り子の台車に対しての加速度を入力信号 τ とする。台車の質量が振子に比べ十分大きいとき、台車加速度は台車に加える力にほぼ比例するので、それほど不自然な仮定ではない。振子の回転に依存するクーロン摩擦を想定すると、振子のダイナミクスは式(3-23)で表される。

$$-(J + ml^2)\ddot{\theta} - \left(\frac{2}{1 + \exp(-a\dot{\theta})} - 1 \right) + mgl \sin \theta = ml\tau \cos \theta \quad (3-23)$$

ただし、

m :振子重量	0.0411 [kg],	l :振子の長さ	1.26 [m],
J :振子の慣性モーメント	0.0647 [kg m ²],	θ :振子傾き角	[rad],
τ :入力加速度	[m/s ²],	g :重力加速度	9.806 [m/s ²].

である。式(3-23)の第2項目はクーロン摩擦に相当する項である。この倒立振り子制御の問題は、目標値一定 ($\ddot{\theta}, \dot{\theta}, \theta$ が常に0) であるため典型的なレギュレータ問題である。ここでは学習によって神経回路モデルに制御対象すなわち振子の逆モデルが形成されることを明確に示すため、NNFCが獲得する関数(振子の逆モデル)がパラメータ(シナプス荷重)に関し線形になるように、前処理として入力 $\ddot{\theta}, \dot{\theta}, \theta$ を式(3-24)で変換した後、式(3-25)にしたがってNNFCの出力を算出した。このようなパラメータに関する線形化の方法は、ロボットの適応制御^{67,68,69,70)}や神経回路モデルを使った制御の研究⁹⁾で用いられている。

$$p_0 = \tan \theta$$

$$p_1 = \left(2 / (1 + \exp(-a\dot{\theta})) - 1 \right) / \cos \theta \quad (3-24)$$

$$p_2 = \ddot{\theta} / \cos \theta$$

$$\tau_n = \sum_{k=0}^2 w_k p_k \quad (3-25)$$

各々のシナプス荷重が式(3-26)の値を取ると、NNFCは任意の入力で逆モデル計算に従っ

た出力をする.

$$\hat{w}_0 = g, \quad \hat{w}_1 = -\frac{1}{ml}, \quad \hat{w}_2 = -\frac{J + ml^2}{ml} \quad (3-26)$$

3.2.1で述べた学習スキームに従ってシナプス荷重を調整するとき、それらの値が式(3-26)で示す値になることを以下で確認する. シミュレーションではフィードバック用の位置と速度信号は状態量が計測可能として使用し、加速度信号は速度信号の後退差分により算出したものを使用した. また外部入力は、3.2.1で述べた条件2を満足するよう、次式で表されるOrnstein Uhrenbeck 過程⁷¹⁾を使用した.

$$\frac{d\tau_{ext}}{dt} = -a\tau_{ext} + b\varepsilon \quad \begin{array}{l} a, b : \text{constant coefficient} \\ \varepsilon : \text{White noise} \end{array} \quad (3-27)$$

CFCに設定したフィードバックゲインは $K_2 = 1, K_1 = 3.5, K_0 = 20$ である.

学習中に各シナプス荷重が目標値に収束して行く様子をFig. 3.5 に示すが、学習が進むにつれNNFC内部のパラメータは目標値に収束し、約60[s] (シミュレーション時間)ですべてのパラメータがほぼ目標値に収束している. Fig. 3.6は、その学習中のNNFCに対する誤差信号 $\tau_c + \tau_{ext}$ およびNNFCの出力 τ_n の各々の自乗移動平均 (2.5万回の学習毎)であるが、学習時間の増加と共に誤差が減少している様子を示している.




Fig. 3.5 Time courses of synaptic weights (adaptive parameters) during IDML.

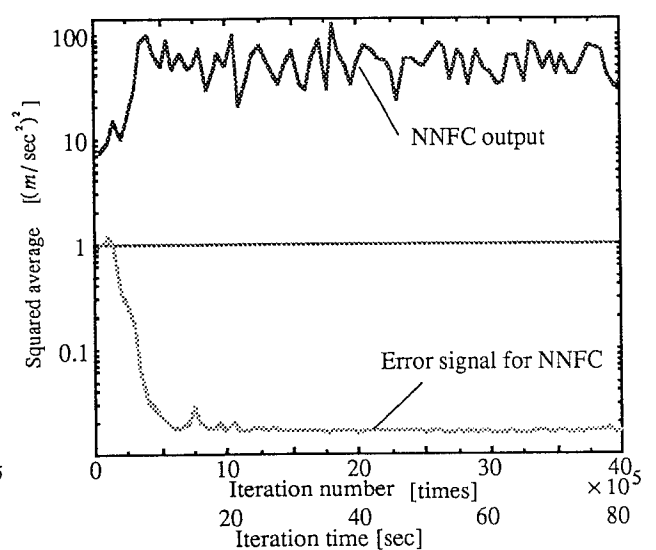


Fig. 3.6 Moving averages of the square of the NNFC output and the square of the error for NNFC during IDML.

次に、学習による応答性の改善の様子を比較をするために、Fig. 3.7 に式(3-28)で表わされる外部入力 τ_{ext} に対する学習前後の応答と目標応答および従来型の線形コントローラを用いたときの応答を示す。

$$\tau_{ext} = -5\sin(\pi t/2) \quad (3-28)$$

従来、線形コントローラの設計は、制御対象を動作点近傍で線形化した簡単なモデルを考え、そのモデルが目標応答を出力するように各線形フィードバックゲインを決定するのが一般的である。応答性の比較のためにここで使用した線形コントローラも、その設計法に従い、振子の角度が0の近傍で線形化しかつ摩擦を考慮しない式(3-29)で表されるモデルを想定し、そのモデルが外部入力 τ_{ext} に対して目標応答が得られるように設定した。

$$-(J + ml^2)\ddot{\theta} + mgl\theta = ml\tau \quad (3-29)$$

この線形コントローラを用いた場合にはFig.3.7(a)からもわかるように、コントローラ設計の際に考慮していない「制御対象の構造による非線形性」と「摩擦」により、外部入力に対しCFCによって規定される目標とする応答が得られていない。これに対し、学習後には目標に一致した応答が得られている。また、Fig. 3.7 (b) に学習後に同じ外部入力を与えたときのNNFCとCFCの出力の様子を示す。NNFCが補償をかけた結果、CFCからの出力が制御対象に加わる外部入力を打ち消すように働いており、すなわち式(3-9)で表される規範モデルにしたがった応答が得られている。

以上より、前節で提案した「逆モデル学習」を行うことにより、NNFCによって制御対象のダイナミクスが補償され、目標応答が得られることが確認できた。




Fig. 3.7 (a) The responses of the controlled object for external input in three conditions (Controlled by linear controller, Before learning, After learning),
(b) NNFC and CFC output responses after learning.

3.3.2 非線形レギュレータ学習による倒立振り子制御

この学習スキームのシミュレーションでは、提案した学習則が一般的な神経回路モデルでも十分有効であることを示すため、NNFCとしてFig.3.8に示す3層のMLPを使用した。ここで、入力層は振り子の位置・速度を入力するための2つの線形ユニット、中間層は5つのシグモイド関数を持ったユニット、出力層は1つの線形ユニットで構成し、線形な部分の学習を促進するため入力層から出力層への直接結合を設けている。また対象とした問題の対称性から各ユニットに対するバイアス入力はない。




Fig. 3.8 Three layered neural network for NNFC used in nonlinear regulator learning

制御対象およびCFCは前例と同じく各々式(3-23), 式(3-2)で表されるものを使用し, 各パラメータも逆モデル学習のシミュレーション例と同様に $K_2 = 1, K_1 = 3.5, K_0 = 20$ と設定した. またここでは, 1.05[rad]からの自由応答5[s]を繰り返し行い, 前節で説明した非線形レギュレータ学習スキームに従って各時点でのCFCの出力をNNFCに対する誤差信号として学習を行った.

まず, 学習途中での両フィードバックコントローラ出力の移動平均の変化の様子(1回の自由応答毎)を Fig. 3.9 に示す. 学習が進行するにつれ, CFCからの出力が減少していくのがわかる.

次に, Fig. 3.10 (a), (b) に目標とする応答と学習前後の応答と従来型の線形コントローラでの応答を示す. 線形コントローラは逆モデル学習の時と同様に, 制御対象を原点近傍で線形化しかつ摩擦がないとして目標応答が得られるよう設計したものである. 逆モデル学習の際示した結果と同様, 線形コントローラを用いた制御では設計時に考慮しなかった制御対象の特性により大きく目標応答からはずれ, かつ対象の非線形性のため初期位置により違う挙動を示している. 学習後の応答は大幅に改善されどちらの初期位置からも目標応答にほぼ近い軌道が得られている. 学習時と異なる始点(学習は1.05[rad]からの応答で繰り返し学習を行っている)からも目標応答にほぼ等しい応答が得られていることは, MLPを用いたこの学習が汎化能力を持っていることを示している. しかし, 学習後の応答は, 逆モデル学習で示した結果 (Fig.3.7(a)) ほど目標応答に一致していない. これは逆モデル学習では, パラメータに関し線形化しNNFCが目的関数をほぼ完全に実現可能であるのに対し, この学習では目的関数を未知として比較的小さなサイズの3層のMLPを用いたためである. 前述のように, 数学的には適当な3層のMLPによって任意の非線形関数を任意の精度で実現することが示されているが^{63,64)}, 実際の問題では, この例でわかるように, 神経回路モデルのサイズやローカルミニマムへのトラップによって目的関数の近似精度は制限されるため, 現実の制御対象への利用に当たってはそれら関数近似能力の問題をあわせて考えることが必要である. また, 学習後の応答時のCFCとNNFCの出力の時間応答を Fig.3.11 に示す. NNFCの出力が非線形応答を示しているのは, 対象の非線形性を補償してCFCに設定した線形の目標特性に近づくように学習が行われた結果である.

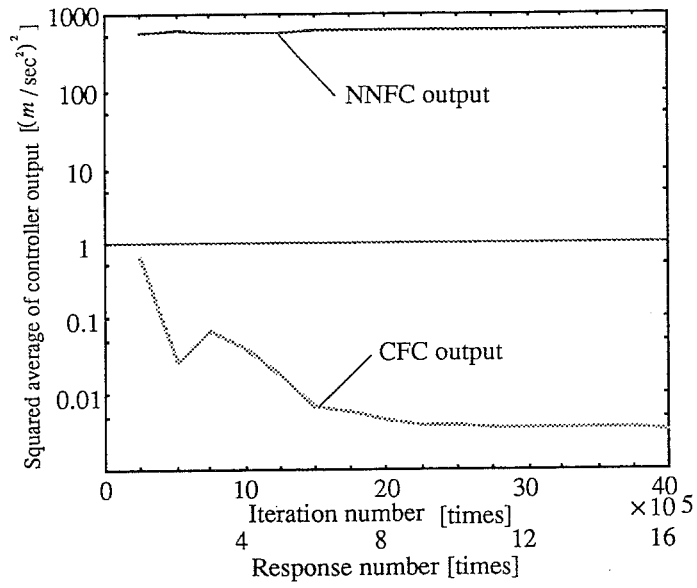


Fig. 3.9 Moving averages of the square of the NNFC output and the error for the NNFC during NRL

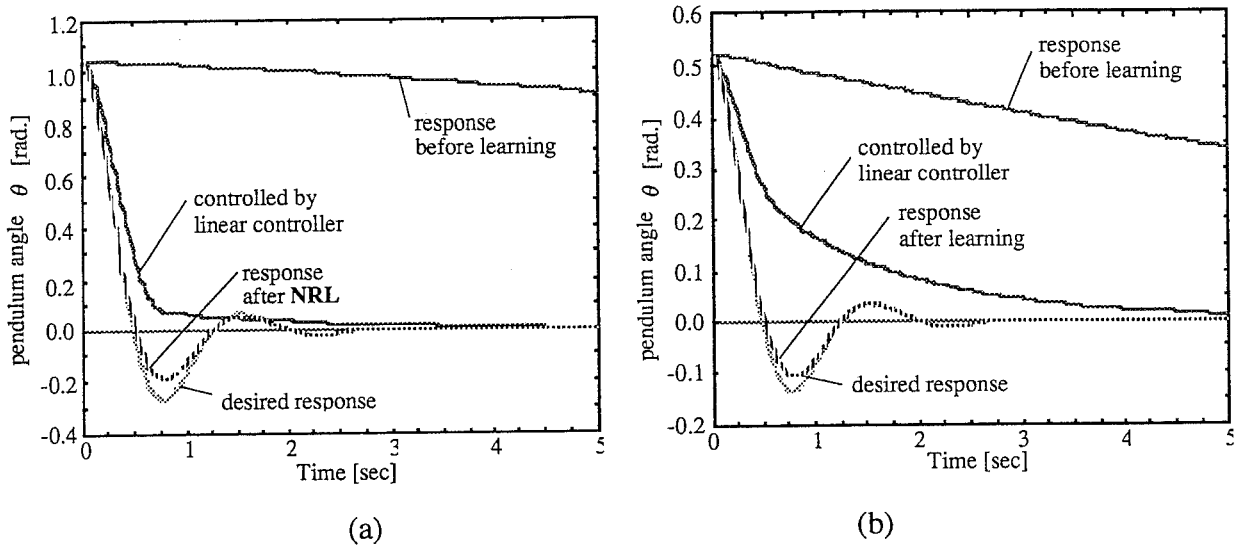


Fig. 3.10 (a) The responses of the controlled object from initial position of 1.05[rad]. (b) The responses of the controlled object from initial position of 0.524[rad]

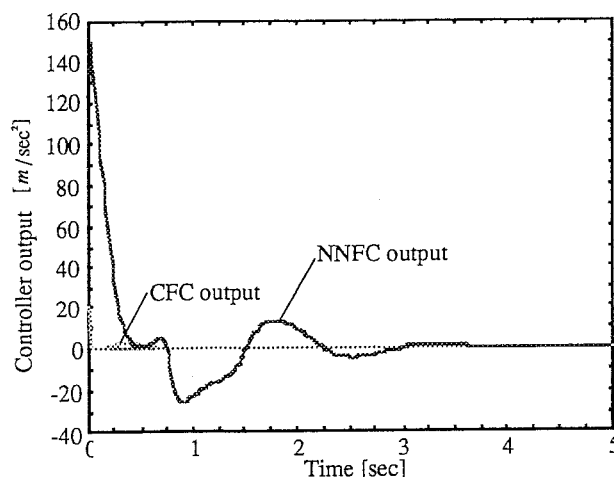


Fig. 3.11 CFC and NNFC output during autonomous response after IDML. (initial position 1.05[rad])

3.3.3 2リンクマニピュレータの学習型インピーダンス制御

次に、逆モデル学習の応用として学習型インピーダンス制御が実現できることを、平面内シリアル2リンクのマニピュレータのシミュレーションによって確認する。使用したマニピュレータモデルは取り付け台に近いほうからlink1, link2 と呼び、表2のようなスペックに設定した。

Table 3.1 Parameters of 2-link manipulator

	link1	link2
mass [kg]	0.90	1.1
link length [m]	0.25	0.35
Inertia moment at center of gravity [kg m ²]	0.010	0.020

学習に使用した神経回路モデルは3層のパーセプトロン型のもので中間層には13個のシグモイド関数を使用し、入力層から出力層への直接結合を全入力に対し設けている。

入力信号は神経回路網の学習を容易にするために逆ダイナミクスモデルに必要な先見的知識を一部利用するため、次に示す7つを使用した。ただし、これだけの入力では、逆モデル学習による倒立振り子制御の際のように全パラメータに関して線形にはならないため、神経回路モデルNNFCが非線形関数を学習しなくてはならない。

$$\ddot{\theta}_1 \cos \theta_2, \dot{\theta}_1, \ddot{\theta}_1, \sin \theta_2, \dot{\theta}_2, \ddot{\theta}_2, \dot{\theta}_2 \cos \theta_2 \quad (3-30)$$

また、学習時の条件は次のように設定している。

- ・速度信号は状態量，加速度信号は速度信号の差分
- ・サンプリング時間は2[ms]
- ・外部入力 Ornstein Uhrenbeck 過程

学習時に設定した目標インピーダンス（規範モデル）は

$$M(\ddot{x} - \ddot{x}_r) + B(\dot{x} - \dot{x}_r) + K(x - x_r) = F_{ext} \quad (3-31)$$

$$M = \text{diag}[0.10, 0.10], \quad B = \text{diag}[2.0, 2.0], \quad K = \text{diag}[20, 20]$$

すなわちCFCには、

$$F_c = -[M(\ddot{x} - \ddot{x}_r) + B(\dot{x} - \dot{x}_r) + K(x - x_r)] \quad (3-32)$$

と設定した。ここで、 $\text{diag}[\cdot]$ は対角行列を表わし、 $x = [x, y]^T$ である。

学習時のNNFCへの誤差信号とNNFCの出力の変化の様子をFig.3.12(a)に、学習時にマニピュレータの先端が通過した作業座標系での軌道の一部をFig.3.12(b)に示す。学習を、特定の軌道に対してではなく、Fig.3.12(b)に示すようなランダムな軌道に対して行うことにより、学習終了後、学習を行った空間において逆モデルと等しい出力が得られることを狙っている。

学習前および学習後のシステムに参照軌道を与えたときの自由応答の作業座標での軌跡の様子を各々Fig.3-13(a)と(b)に、X,Y各軸に投影した時間推移の様子をFig.3.14に示す。学習前の状態において、NNFCの出力は常に0である。NNFCが運動範囲においてほぼ完全な逆モデルと同じ出力をする場合には、動作開始から十分時間が経過したときの応答は参照軌道にほぼ誤差ゼロで追従することになる。Fig.3.13(b) およびFig.3.14 で示す学習後の状態においては、学習前に比べ大幅に参照軌道に近い軌道が得られ、学習が有効

に働いていることがわかる。より一層学習結果を改善するためには神経回路モデルの構成や学習方法などを工夫する必要がある。なお、このシミュレーションでは目標インピーダンス（規範モデル）として、

$$M = \text{diag}[0.10, 0.10], \quad B = \text{diag}[10, 10], \quad K = \text{diag}[20, 20] \quad (3-33)$$

を用いて制御している。

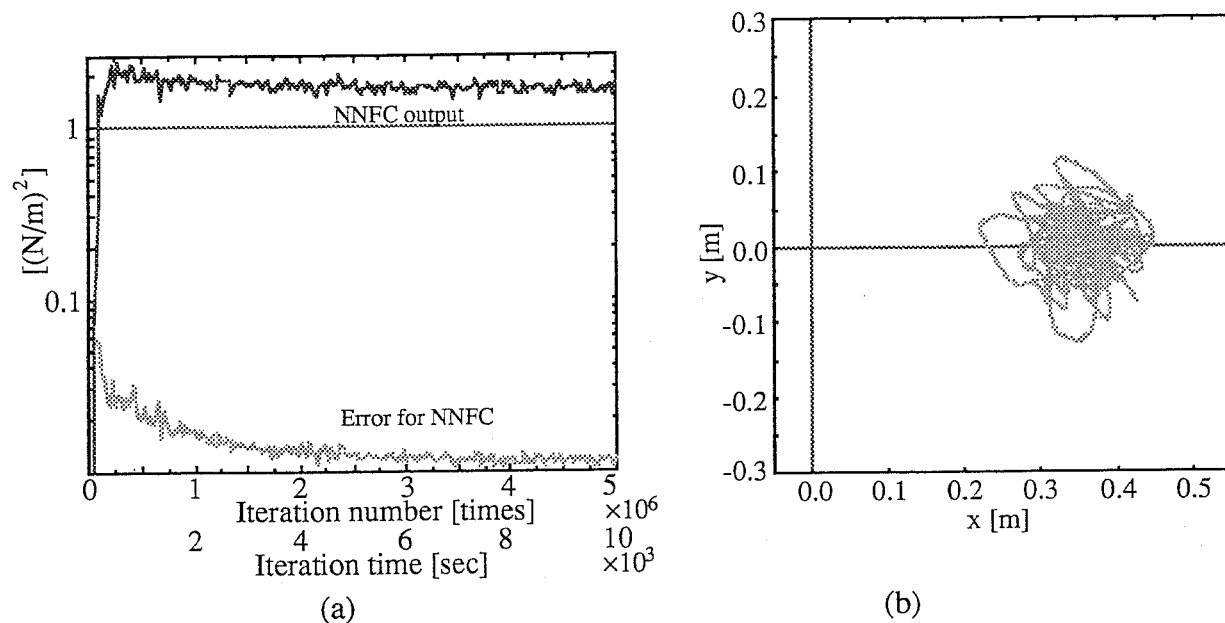


Fig. 3.12 (a) Moving average of squared error and squared NNFC output.
(b) Sinusoidal trajectory in the learning period for first 2000 iterations

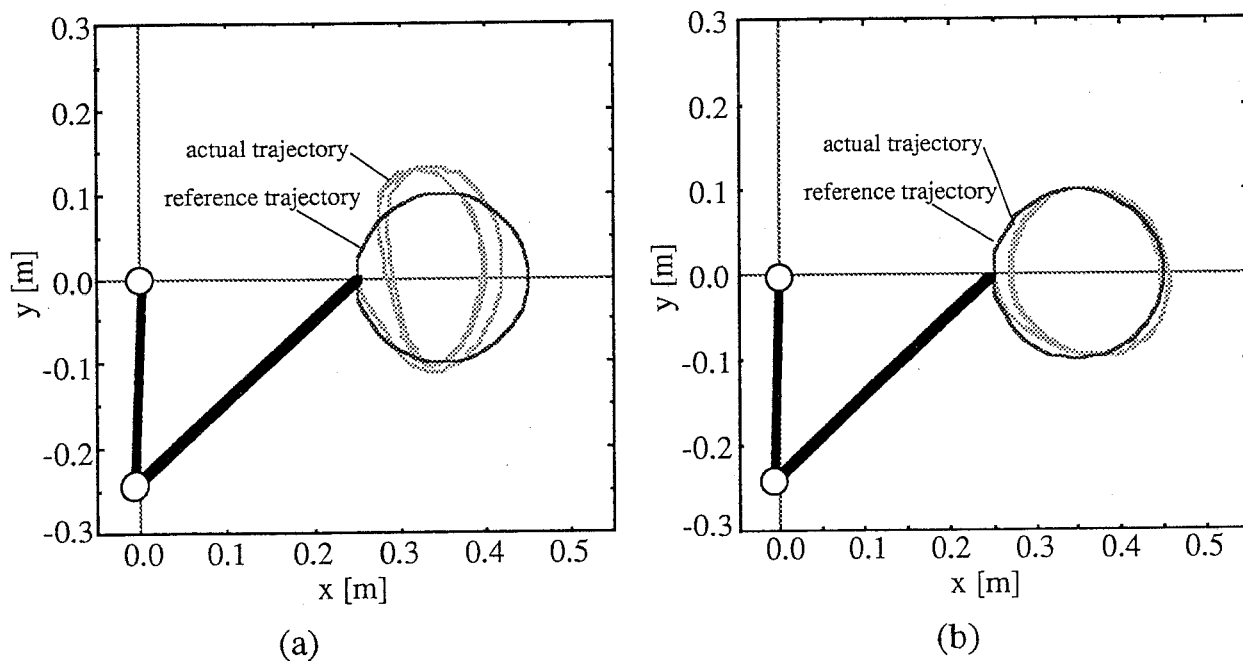


Fig. 3.13 Free movement following reference trajectory. (a) before learning, (b) after learning

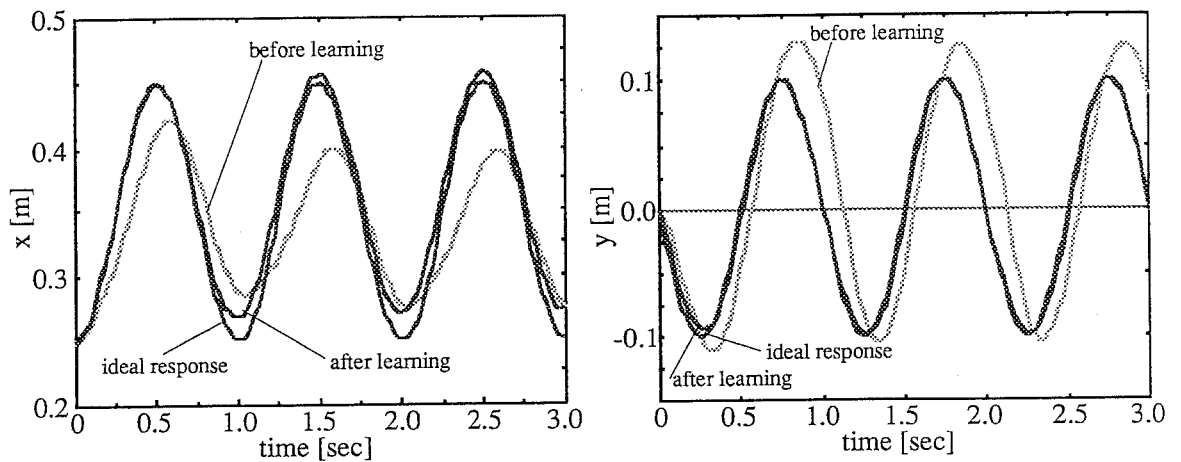



Fig. 3.14 Time courses of free response of X, Y axis following reference trajectory

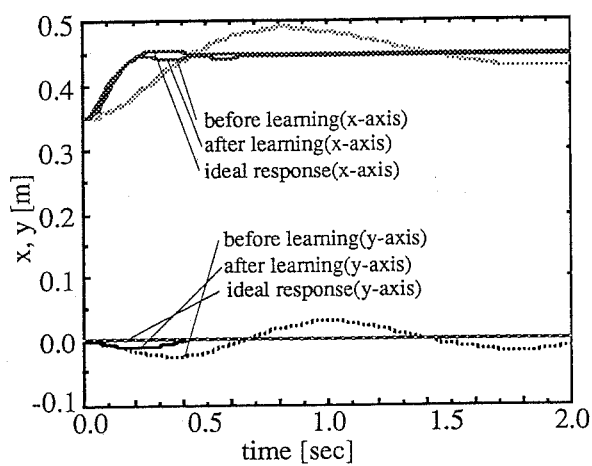
次に、学習前、学習後、理想的な逆モデルを得た場合の、x,y各軸に平行なステップ状の外力をマニピュレータ先端に加えたときのマニピュレータの動作の様子を示す。この時のCFCのパラメータは、

$$M = \text{diag}[0.10, 0.10], \quad B = \text{diag}[2.0, 2.0], \quad K = \text{diag}[20, 20] \quad (3-34)$$

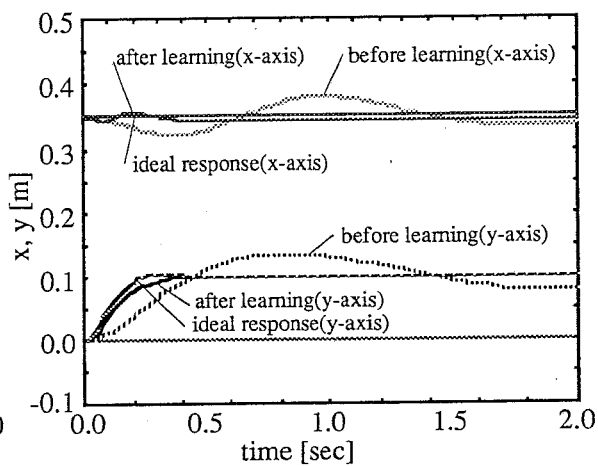
である。Fig.3.15(a) はx,y座標上での軌跡を、Fig.3.15(b)と(c)は各外力の場合でのx,y各軸方向の移動量の時間推移の様子を示している。図から判るように外力に対する応答も、学習前の状態に比べて大幅に改善されており、学習が成功していることがわかる。



(a)



(b)



(c)

Fig. 3.15 Improved response for the force inputs at the end effector. (a) Trajectories in Cartesian space. (b) Time courses for the x-axis direction step force input at the end effector. (c) Time courses for the y-axis direction step force input at the end effector.

3つめの例として、Fig.3.16, 3.17 に自由運動と接触運動を行うときの学習前後の、(a) マニピュレータ先端の軌道と、(b)先端にかかる力の時間変化を示す。ここで、壁は硬いバネ（剛性係数=10⁶[N/m]）でモデル化している。この運動では、目標インピーダンスとなるCFCをHoganの方法⁷²⁾に合わせて次のように設定した。

$$F_c = -[M\ddot{x} + B\dot{x} + K(x - x_r)] \quad (3-35)$$

学習前後でのシミュレーションの際の M, B, K の設定値は次の通りである。

$$\text{学習前 } M = \text{diag}[0.1, 0.1], \quad B = \text{diag}[7.0, 7.0], \quad K = \text{diag}[100, 100] \quad (3-36)$$

$$\begin{aligned} &M = \text{diag}[0.1, 0.1], \\ \text{学習後 } &B = \text{diag}[7.0, 7.0] \text{ (free movement phase)}, \quad B = \text{diag}[700, 7.0] \text{ (contact phase)} \\ &K = \text{diag}[100, 100] \end{aligned} \quad (3-37)$$

学習前には、自由運動の状態においても参照軌道への追従性がわるく、壁接触時にはマニピュレータの粘性が小さいためバウンドしてしまい滑らかに接触状態に移行できない。また、インピーダンスを接触運動に合うように調節していないため、壁との衝突時に大きな衝撃を受けていることがFig.3.16(b)よりわかる。これに対し、Fig.3.17(a)で示すように学習後の状態においては、目標軌道への追従性は改善され、かつFig.3.16(b)とFig.3.17(b)の比較からわかるようにインピーダンスを調節しているために接触時に受ける衝撃力が大幅に軽減されている。また、接触時にはx方向（壁と垂直方向）には粘性を高くしているため接触時の動作も安定な接触を行っており、目標軌道との誤差に比例した力を壁に与えているのがFig.3.17(b)よりわかる。以上の結果より、接触運動においても有効であるインピーダンス制御が学習により可能であることが示された。




Fig. 3.16 Free movement & contact task before learning.
(a) Trajectory of end effector, (b) External force for the end effector

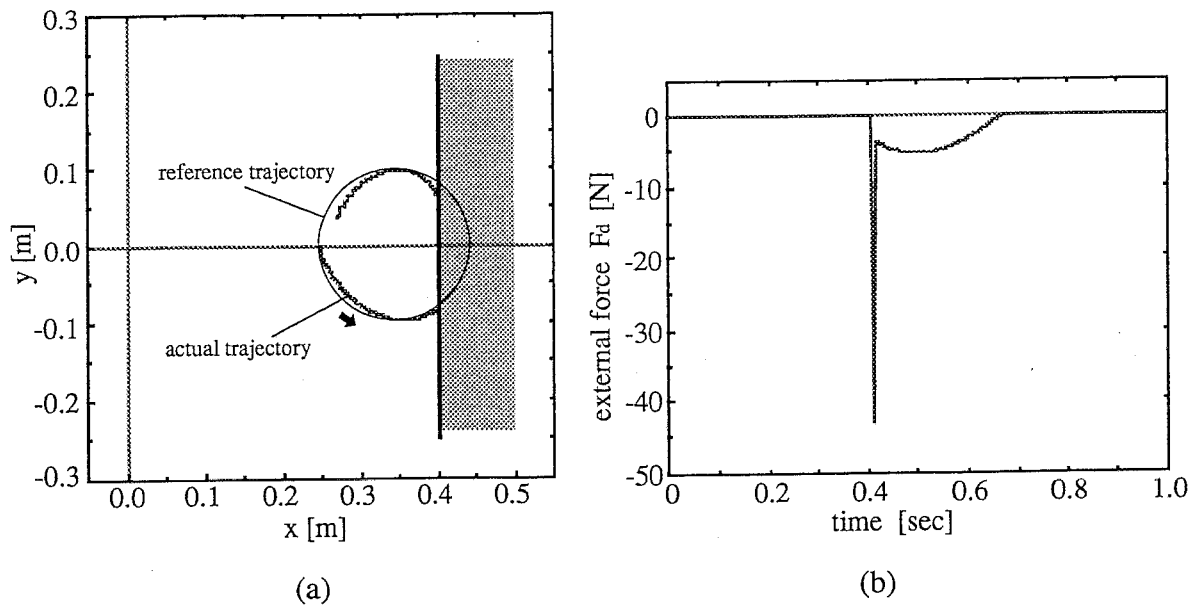


Fig. 3.17 Free movement & contact task after learning.
 (a) Trajectory of end effector, (b) External force for the end effector.

3.4 考察

ここでは始めに、上で提案した2つの学習スキームの類似点、相違点について明確にし、次にそれらの方法と神経回路モデルを用いた他の学習型フィードバック制御の方法との関係について考察する。そして最後に、逆モデル学習の応用である学習型インピーダンス制御が従来のインピーダンス制御と比べてどのような利点があり重要であるかを検討する。

3.4.1 逆モデル学習と非線形レギュレータ学習の比較

2つの学習においてNNFCが獲得すべき目的関数（式(3-4)と式(3-17)）を比較をすると、逆モデル学習のほうはフィードバック信号によって制御対象の特性の加速度に依存する項まで補償するのに対し、非線形レギュレータ学習では、参照軌道の加速度によってフィードフォワードの補償はされるが、実際の加速度項はフィードバックによって補償されず、加速度係数の非線形性を位置、速度の項に掛けることにより自由応答において規範モデルに従った線形応答をすることがわかる。この違いは外部入力が入ったときの応答の違いとして現われ、学習完了後、逆モデル学習では外部入力連続的に入っているときにも規範モデルに従って線形応答を示すのに対し、非線形レギュレータ学習で

はもはや規範モデルに従って応答しなくなる。ただし、外部入力が無くなれば、両者とも規範モデルに従った線形応答を示す。

以上述べた特性だけを考えると、逆モデル学習のほうが適用範囲が広いようにも思えるが、逆モデル学習は制御対象のダイナミクスをすべてフィードバックによって補償するため、加速度計測の精度やサンプリング時間刻み、学習時に加わる外部入力・参照軌道などの入力の仕方により不安定になりやすい場合がある。実際の制御に利用する場合は学習スキームの選択は制御する対象と利用可能な信号などの条件、そして制御の要求にあわせて選択するのが望ましいと考える。Table 3.2 に逆モデル学習と非線形レギュレータ学習の主な違いをまとめる。

Table 3.2 Summary of differences between IDML and NRL

	Inverse Dynamics Model Learning (IDML)	Nonlinear Regulator Learning (NRL)
Neural net. input	$\ddot{\theta}, \dot{\theta}, \theta$	$\ddot{\theta}_r, \dot{\theta}_r, \theta_r, \dot{\theta}, \theta$
Training error	$\tau_{fb} + \tau_{ext}$	τ_{fb}
Learning condition	$\tau_{ext} \neq 0$ or $\ddot{\theta}_r \neq 0$ $\tau_{ext}, \ddot{\theta}_r$: continuous and bounded	$\tau_{ext} = 0$
Objective function for neural net. where controlled object dynamics is: $R(\theta)\dot{\theta} + N(\theta, \dot{\theta}) = \tau$	$\Phi_d = R(\theta)\ddot{\theta} + N(\theta, \dot{\theta})$	$\Phi_d = N(\theta, \dot{\theta}) + R(\theta)\ddot{\theta}_r$ $+ R(\theta)K_2^{-1}(K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta))$
Controlled object response after learning	$\tau_{ext} = 0, \tau_{ext} \neq 0$ $K_2(\ddot{\theta} - \ddot{\theta}_r) + K_1(\dot{\theta} - \dot{\theta}_r) + K_0(\theta - \theta_r) \equiv \tau_{ext}$	$\tau_{ext} = 0$ $K_2(\ddot{\theta} - \ddot{\theta}_r) + K_1(\dot{\theta} - \dot{\theta}_r) + K_0(\theta - \theta_r) \equiv 0$ $\tau_{ext} \neq 0$ $(I + R(\theta)K_2^{-1}) \times$ $(K_2(\ddot{\theta} - \ddot{\theta}_r) + K_1(\dot{\theta} - \dot{\theta}_r) + K_0(\theta - \theta_r)) \equiv \tau_{ext}$

3.4.2 神経回路モデルによる他の学習・適応制御手法との関係

神経回路モデルのロボット制御への応用として、「直接逆モデリング」手法を使って神経回路モデルに逆キネマティクスモデル^{53,54)}や逆ダイナミクスモデル^{55,56)}を学習させて制御に用いる研究が多く見られた。この手法では、学習のための”誤差”は、外部から陽に与えられる。しかし3.1で指摘したように、制御対象が冗長性を持つ場合には逆写像が「1対多」になるため、この方法をそのまま使用することはできず、何らかの拘束条件により冗長性を解いた教師信号を与えなければならない。神経回路モデル制御器を学習させる上で、冗長性を解決しながら制御器の出力の目標値あるいは誤差を正しく得ることは基本的かつ重要な問題であり、それを解決できる手法が望ましい。

Jordan⁵⁷⁾, Narendra & Parthasarathy⁵⁸⁾が用いた順逆モデリングでは、制御対象への入力
の誤差を出力の誤差から得るのに、学習によって獲得した制御対象の順モデルを逆伝搬
して（すなわち出力の入力に対するヤコビ行列の転置を利用して）変換しており、これ
は非線形最適化の一手法である「最急降下法」に相当する。この順逆モデリングを利用
する際、冗長性の問題を陽に扱うためには（すなわち、勝手な解に陥らないようにする
ためには）「なめらかさの拘束条件(Smoothness constraint)」などを用いる¹³⁹⁾。また、川
人らが提案し、本論文で適応方法を拡張した「フィードバック誤差学習」は、「広義
ニュートン法」に相当することが示され、これは入力誤差を計算するフードバック制御
器が冗長性に対する拘束条件を与えると説明されている⁷³⁾。

先に提案した「逆モデル学習」や「非線形レギュレータ学習」では、フィードバック
誤差学習を用いて非線形制御器の獲得を行うメカニズムについて説明した。ここで、上
記の入力誤差を得るための降下法とニュートン法というアルゴリズムの差に着目すると、
Fig.3.18 に示すように規範モデルより算出される目標加速度 $\ddot{\theta}_d$ (式(3-38)) と計測した
加速度との誤差を、制御対象の順ダイナミクスモデルを誤差逆伝搬して制御器を学習さ
せるJordan流⁵⁷⁾の学習によって提案した2つの学習スキームと同様の非線形制御器の獲
得を行う学習スキームも考えられる。

$$\ddot{\theta}_d = K_2^{-1} \left(\tau_{ext} + K_1 (\dot{\theta}_r - \dot{\theta}) + K_0 (\theta_r - \theta) \right) + \ddot{\theta}_r \quad (3-38)$$

ここで、 $(\tau_{ext} \neq 0$ または $\ddot{\theta}_r \neq 0)$ かつ NNFC を式(3-3)の様に設定したとき、逆モデル学
習となり、 $\tau_{ext} = 0$ かつ NNFC を式(3-15)の様に設定したとき、非線形レギュレータ学習

となる。この学習手法では、ある程度正しい順モデルが得られれば、逆伝搬する誤差が NNFC の学習に正しく作用し、規範モデルで規定される目標応答を実現するのに必要な非線形関数を獲得できる可能性がある。フィードバック誤差学習による方法との学習パフォーマンスの比較は制御対象に依存する問題であるため本論文では扱わなかったが、このような順モデルの誤差逆伝播を利用するためには、効率的な順モデルの獲得手法が必要であろうと考える。

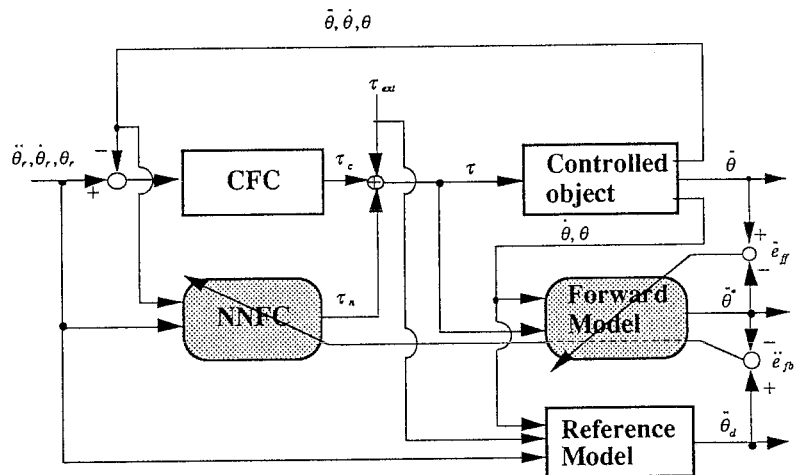


Fig. 3.18 IDML and NRL scheme by using back-propagation through a forward model.

The error between the actual output of the controlled object and the output of the forward model, e_i , is for forming the forward model. The error produced from the tracking-error, e_{tr} , is for training the NNFC by using back-propagation through the forward model of a controlled object (i.e., partial derivative of the output error with respect to the input of the forward model).

さて、Sanner & Slotine⁶⁵⁾は、本章で提案した「非線形レギュレータ学習」に類似の方法として、制御対象の加速度を計測する必要のない（一般には、制御対象がn次の微分方程式で表わされるとき、n-1次までの状態量の計測でよい）Gaussian networkによる直接型適応制御を提案している。そのスキームの収束性は、適当な数の基底関数と線形パラメータによって非線形関数を適当な精度で近似できるという事実と、Slotine & Li⁷⁴⁾の提案した線形化パラメータによる直接型適応制御の証明の手法とを使って示されている。しかし、そのスキームは、参照軌道 θ_r に対する完全な追従を目的としており、外部入力がある場合やレギュレータ問題に対して単純に適用することは困難である。これに対し、提案した「逆モデル学習」や「非線形レギュレータ学習」のスキームは、加速度の計測は必要であるが、軌道誤差の収束の仕方が規範モデルに沿うように学習を行うため、外部入力がある場合やレギュレータ問題を扱うことができるメリットをもっている。

3.4.3 インピーダンス制御の学習による獲得の重要性

対象物と干渉を持つためには従来のマニピュレータに多く用いられている位置あるいは軌道の制御ばかりでなく対象物に与える力の制御が必要となってくる。そのような状態でのマニピュレータに対する制御方法として力制御⁷⁵⁾やコンプライアンス（あるいはステイフネス）制御⁷⁶⁾が提案された。しかし、環境との干渉の状態が状況と共に変化して行くとき、各々独立の制御方法だけではうまく行かないことが指摘された⁴⁰⁾。Hogan⁴⁰⁾は制御対象および操作対象のダイナミクスに着目し、自由空間での運動と拘束条件下での運動の統一的な制御方法としてインピーダンス制御を提案した。Hogan⁷²⁾はこの制御方法を用い、「操作対象の動力学的特性」と「要求する挙動」に合わせて自分のインピーダンスの適切な設計を行うことにより、自由運動から干渉状態へスムーズに移行することが可能となる事を、作業座標系でのインピーダンス制御による実験で示した。その研究では、マニピュレータのインピーダンスを自在にコントロールするために、力センサ信号と速度、位置の信号を用いてマニピュレータのダイナミクスに対する補償をかける方法が提案された。また、館ら⁷⁷⁾は力センサを用いずに加速度を計測し同様の補償をする方法を示した。さらにインピーダンス制御によって生成される軌道は干渉している相手の情報（例えば操作対象の剛性、粘性、慣性）を反映しているため、それらの情報を利用し、マスタスレーブマニピュレータ制御での伝達情報の減少を試みた例もある⁷⁸⁾。Table 3.3 に、Hogan, 館ら, 著者らの提案する方法（学習型インピーダンス制御）において、検出すべき信号と予め必要な計算を比較して示す。

Table 3.3 Sensing signals and prepared calculation in three methods of impedance control.

	sensing signals	Prepared calculation
Hogan	$\theta, \dot{\theta}, F_{ext}$	$R, N, \Psi, J, \dot{J}, J^T, J^{-1}$
Tachi	$\theta, \dot{\theta}, \ddot{\theta}$	$R, N, \Psi, J, \dot{J}, J^T$
Proposed	$\theta, \dot{\theta}, \ddot{\theta}$ F_{ext} (in learning phase)	Ψ, J, \dot{J}, J^T

Here, R, N, Ψ, J are functions which satisfy following equations.

$$\tau = R(\theta) + N(\theta, \dot{\theta}), \quad x = \Psi(\theta), \quad J = \partial\Psi(\theta)/\partial\theta, \quad F_{ext} : \text{external force}$$

表に示すように、Hogan, 館らの研究においては制御対象であるマニピュレータのダイナミクス R, N が既知であるとしており、検証実験においてはダイレクトドライブ方式 (DD方式) によるマニピュレータを使用し、そのダイナミクスを予め同定して制御のための計算に用いている。DD方式のロボットはダイナミクスが比較的同定しやすい反面、トルク重量比が低いため、高速な動作をさせる際にインピーダンス制御での仮想慣性を低く設定することが困難であるという欠点をもつ。これはすなわち、目標インピーダンスを保持した状態での制御可能な範囲 (インピーダンス制御可能空間⁷⁾) を狭くしてしまうことになる。また、一般に使用されているマニピュレータはギアの摩擦やバックラッシュ、アクチュエータの非線形特性あるいは使用中の特性変化など多くの不確定要素が存在しているため、正確なパラメータ同定が困難となり、それらの不正確な知識のみによる固定ゲイン式の制御では低いパフォーマンスしか得られないことが予想される。さらに、インピーダンス制御を生体運動系のモデルの候補として考える場合、制御対象のダイナミクスは既知ではなく年月とともに変化するため、その学習モデルを考えることが必要である。

本報告で提案した方法は学習によりマニピュレータの逆ダイナミクスを獲得するため、予めダイナミクスに関する情報を知る必要がなく、減速器などの要因によって非線形の不確定要素がある場合などのモデル化困難な場合にも適用が可能であると考えられる。しかし、この学習制御がうまく機能するためには学習が成功することが必要であるが、実際には学習データの選択や使用する神経回路モデルのタイプやサイズを選択など解決が困難な問題もある。実際の問題に適用する際には本手法を従来の手法に対して補助的に用いることにより、マニピュレータの構造など既知の知識を利用して学習を行うことが有効であると考えられる。

3.5 まとめ

本章では、制御対象の内部モデルを獲得し制御性を改善する手法として、フィードバック誤差学習を使った神経回路モデルによる非線形フィードバック制御器の学習スキームを提案し、一般的な制御モデルとして考察した。これらの学習によって非線形制御器である神経回路モデルが制御対象の非線形ダイナミクスを補償し、その結果、制御対象は規範モデルで与えられた応答をするようになる。ここでは、倒立振子の制御、2リンクマニピュレータの学習型インピーダンス制御を例にとり、提案したスキームの有効性を示したが、これらは一般的な非線形補償制御器を獲得する手法の1つとして、さまざま

な制御対象に利用できるものと期待できる。また、これらの学習スキームは基本的には制御対象の非線形性に関する知識を前もって必要としないが、実際の問題に適用する際には、従来適応制御で使われている既知の非線形構造を利用してパラメータに関し線形化する手法も併用することが高い性能を得るためには望ましいと考える。

さて一方、人間や動物の運動を考えた場合、これらの制御系は個々の正確な構成要素を集合して運動を実現しているのではなく、視覚・体性感覚などの多くのセンサにより運動を観測し、動作経過・結果の良否などの多重の適応学習をかけることによって多才で正確な運動を実現していると思われる。その意味では、ここで提案したスキームは制御対象への入力と出力のみを使って目的にかなった制御を実現する手法であり、生体系における学習と似た側面を持っていると言えよう。本章で考察したような学習制御メカニズムが、生体の様々な運動系で行われているかどうかということを実際に確認することは容易な作業ではないが、逆に脳での反応を局所的に観察することから全体の運動学習系のメカニズムを推し量ることはさらに困難であろうと考える。複雑な現象を説明しようとすればするほど、ここで行ったような計算論的あるいはAnalysis by Synthesisによる考察を行う必要があり、そこで作られるモデルを検討・検証することによって、脳で観察される現象を説明していくという方法論が重要であろうと考える。本章で提案した内部モデル学習スキームと生体運動学習系の類似性や対応関係については、次章で詳しく考察する。

第4章

小脳における 運動学習適応系の計算モデル

前章までに、内部モデルを使った生体系における運動制御の必然性、内部モデルの獲得とその利用についての一般的な制御モデルとしての考察について説明した。本章の目的は、これまでに解明された解剖学・生理学的知見等を基に、内部モデル獲得が脳の何処で行われているのか、そこから導かれる学習原理は何かを探りモデル化することにある。本章では、はじめにこの章で述べる研究の背景について説明する。そして提案する小脳における様々な運動学習の統一的計算モデルおよびその各論について述べる。

4.1 はじめに

本節では、これ以降の節の説明のまえおきとして、小脳の信号伝達系と適応機構そしてその役割を考察する上での基本的な生理学的知見、および従来の小脳における運動学習モデルについて説明する。次に、4.2節で「フィードバック誤差学習」に基づく統一的計算モデルを提案し、4.3節で小脳外側部における随意運動学習制御モデルで用いられたフィードバック誤差学習における誤差信号の意味を生理学的データと対比させて説明する。そして、4.4節で前庭動眼反射・視機性眼球反応*適応調節系、4.5節で姿勢・歩行制御適応調節系を各々前庭小脳、脊髄小脳における学習適応系として取り上げ、それら系を司る実際の神経回路網と「フィードバック誤差学習モデル」との関連性を、生理学的解剖学的知見や小脳各部位での機能的アナロジおよび運動学的実験結果をもとに考察する。

*視機性眼球運動と呼ばれることもある。本文中では、永雄⁹⁸⁾の使用に従い「反応」を使用する。

4.1.1 小脳の信号伝達系・適応機構・役割

小脳神経の入出力経路，結合関係，構成細胞などの基本的な解剖学・組織学的関係はEcclesらの研究により1960年代後半に解明されてきた。それらに関しては，各々の文献あるいは参考書^{26,28)}に詳しいが，計算論にとって特に重要な事柄としては，(1)小脳皮質構造が一様であること (Fig.4.1に示すように，少ない構成要素を単位として幾何学的に一様に配置している)，(2)小脳入出力神経系は苔状線維(Mossy fiber)と登上線維(Climbing fiber)からの2つの入力経路とプルキンエ細胞(Purkinje cell)からの1つの出力経路に限られること，(3)1つのプルキンエ細胞には登上線維を介してただ1つの下オリーブ核ニューロンから信号が送られること，などが挙げられる。




Fig. 4.1 Structure and signal flow of cerebellar cortex. Synaptic efficacy from parallel fiber to Purkinje cell is modified by climbing fiber signal. (from reference (29))

小脳における信号伝達の変化の仕組み，すなわちプルキンエ細胞における異シナプス可塑性は，小脳片葉でのLTD (long-term depression)として，伊藤²⁶⁾らの生理学的実験によって解明された。これは「苔状線維から平行線維を介しての信号と登上線維からの信号がプルキンエ細胞に同時に到着したとき，平行線維からプルキンエ細胞への信号伝達効率が減少する」というものである。この報告の追試は生理実験の難しさのために時間を要したが，近年，様々な条件下でLTDが確認されてきている^{79,80)}。

また，小脳皮質に位置するプルキンエ細胞での伝達効率の変化を誘発するとされる登上線維信号は，どの小脳皮質部位に対しても下オリーブ (Inferior olive) 核という細胞群から送られていて，その下オリーブ核は，様々な体性感覚受容器や網膜，大

脳皮質などから入力を受けている。皮質部位に対応する入力を見ることは、小脳での学習モデルを考えるうえで、非常に重要なことであるが、この解析も近年進んできた^{30,81,82)}。

さて、小脳皮質は解剖学的に4つ（片葉，虫部，中間部，外側部）の部位に分けられており、それぞれの部位のプルキンエ細胞は異なった小脳核に出力をし、最終的に信号が到達する筋群はそれぞれの小脳核でかなり異なる。それらの小脳皮質部位と機能との関係付けは、臨床学的観察や、部分破壊または冷却による機能的変化の観察に基づく、役割・機能の分析によって行われ、Table 4.1の様にまとめられている²⁹⁾。

Table 4.1 Principal input and output of each cerebellar region.

機能部位	解剖学的部位	主入力	出力核	出力最終目標	機能
前庭小脳	片葉	前庭器官	前庭核	動眼運動ニューロン	前庭動眼反射
脊髄小脳	虫部	脊髄 視聴覚 前庭	室頂核 前庭核	脳幹 運動野	体幹運動制御
脊髄小脳	中間部	脊髄	中位核	大細胞性赤核 運動野	末梢部運動制御
大脳小脳	外側部	大脳	歯状核	小細胞性赤核 運動野 運動前野	運動開始 計画 タイミング

4.1.2 小脳における運動学習モデルの研究

Marr²³⁾とAlbus²⁴⁾は、上に述べたような生理学・解剖学的データを基礎として、「登上線維からの入力によりシナプスの伝達効率に変化し、平行線維への入力からプルキンエ細胞の出力までの間に連想記憶（パターン識別）が出来る」という「小脳パーセプトロンモデル」を提案した。しかしMarr, Albusのモデルは、小脳での学習を一元的に説明はしたが、実際の各々の機能とどのように結び付くのかは、依然不明瞭であった。そこで、多くの生理学者は、様々な運動学習制御と小脳の各部位との関係を生理学的に詳細に研究した。例えば、腕の制御⁸³⁾、姿勢制御⁸⁴⁾、歩行制御⁸⁵⁾、眼球運動制御^{26,86,87)}、条件付け瞬き運動⁸⁸⁾などが上げられる。

生理学・解剖学的立場から、情報処理系をモデル化することに積極的な方向性を示したものとしては、例えば、運動制御のための情報の流れをモデル化する事に重点をおいた伊藤^{89,26)}、Oscarsson³⁰⁾、Brooks⁴⁾などの研究がある。しかし、Oscarsson や Brooksの説明は、詳細な生理学・解剖学・運動学的な知見から学習機能に対して考察を行ってはいるが、両者とも計算論的な視点すなわち「どのような計算を行っているかを明らかにする」という点が欠けている。

これに対し、藤田^{90,27)}は、Marr, Albusの考え方と伊藤らの生理学的実験データをもとに、運動系の学習を説明する「小脳適応フィルタモデル」を提案し、片葉における前庭動眼反射適応機構を計算論的に説明した。小脳片葉における前庭動眼反射・視機性眼球反応の適応制御系を司る機構は、その後の生理学解剖学の研究によってかなり明確になってきており、計算論との詳細な対応が徐々にできるようになってきた。

また塚原と川人²⁵⁾は、これらの研究の流れと、Allen, 塚原⁹¹⁾が提案した随意運動に関わる脳部位の包括的なスキーム、および解剖学・生理学的研究に基づき、随意運動学習の階層制御モデルを発展させた。さらに川人ら⁹⁾は、計算論的に実現可能な小脳外側部における随意運動制御学習系のモデルを提案した。そのモデルでは、3章でも説明したように、基本的なフィードバック制御器の出力信号を、前向きに制御する神経回路モデルの学習の為に誤差信号として用いたことから「フィードバック誤差学習法」と呼ばれている。学習が進行すると、フィードバック制御器の出力は少なくなり、神経回路モデルに制御対象の逆モデルが獲得され、フィードフォワードの制御が実現されるようになる。Fig.4.2は、Fig.3.1(c)の各ブロックに対応する中枢系の部位を示したものである。逆モデルを学習するフィードフォワードの制御器が小脳外側部に、フィードバック制御器が大脳運動野に、フィードバック誤差信号が下オリーブ核より登上線維を介してプルキンエ細胞に送られる信号に、各々対応する。

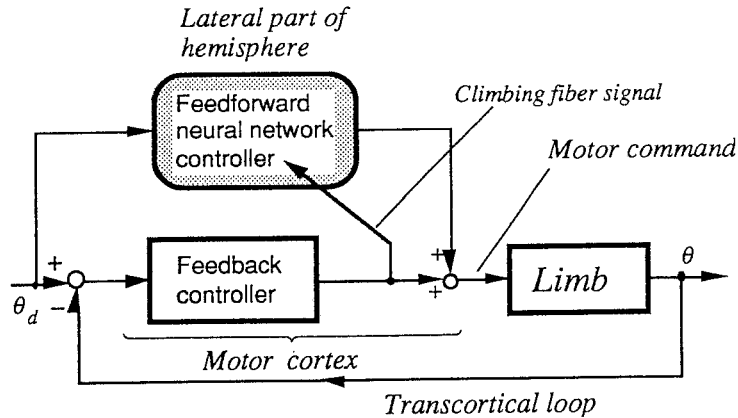


Fig. 4.2 Feedback error learning as a learning mechanism model at lateral cerebellum for voluntary movement.

以上で述べたような生理学的研究やモデリングの研究で明らかにされたように、小脳は、異なった部位ごとに様々な種類の運動学習制御に関わり、またTable 4.1に示したようにその入出力信号も大きく異なる。しかし、本章の始めに説明したように、小脳皮質での細胞間の結合関係は極めて一様である。こういった特徴に基づいて、小脳での運動学習を各々独立に検討するのではなく、各運動系の学習に共通する概念を見つける、すなわち統一的な計算論によって運動学習を解釈しようとする試みが近年いくつかなされてきた。

その1つが、Houk, Barto⁹²⁾の提案した、「小脳の適応パターン生成モデル (Adjustable Pattern Generator Model)」である。それは、小脳深部核と脳幹の間に生じる正帰還ループとプルキンエ細胞のLTDによって、小脳は運動司令の時間的パターンを学習するというモデルである。彼らは、Reinforcement learningと呼ばれる手法⁵²⁾を用いて、腕(1自由度リンク)の簡単な制御のシミュレーションを行った。しかし、その学習モデルを多自由度の制御対象の学習に拡張できるかどうかは不明確である。また、そのモデルは小脳中間部の生理・解剖学的データのみを基本にしたモデルであり、部位ごとの異なった運動学習系の各論を行っていない。

また、Miallら⁹³⁾は、ジョイスティックで動かすカーソルで画面上の指標を追跡させるManual trackingと呼ばれる作業を、小脳を冷却したサルに行わせた実験に基づき、「小脳は、運動の順モデルを使って、視覚や体性感覚の信号伝達系の遅れを補償する機能を実現している」という概念を提唱し、プラントなどの遅れの大きい制

御系のために「遅れ補償器」として考案された「Smith補償器」に相当するものを学習によって実現している（付録4-A参照）と述べた。しかしこのモデルでも、その学習がどのようなアルゴリズムで小脳のハードウェアで実現されているかということや、様々な運動学習を個々にシミュレーションできるかという点に関して説明はなされていない。

以上述べたように、従来の研究においても、小脳での運動学習のモデル化の試みはなされているが、個々の運動機能と結び付けながらそこに潜む共通の計算原理をまとめて説明するまでには至っていない。

4.2 小脳における運動学習適応系の統一スキーム

さて本節では、提案する小脳運動学習の統一的計算モデルの総論として、モデルの全体像と、核となる考え方について説明する。まず、モデルの全体像として、Fig.4.3 にその概念図を示す。図中の矢印は、解剖学・生理学的事実に基づいて描いた情報の流れを表している。図の中で、Premotor networkと呼んでいるものは、筋肉に送る運動司令を生成する部位を表し、随意性の高い運動に関わっている大脳皮質運動野から脳幹・脊髄レベルの反射弓までを含む。この図ではその運動司令生成系を3つのレベル (1)Sensory signal (観測信号) を主な入力とするPremotor network (脊髄反射系など)、(2)高次中枢信号と観測信号の両方を入力とするPremotor network (脳幹を介する運動司令生成系など)、(3)高次中枢信号を主な入力とするPremotor network (大脳を介する運動司令生成系など)、で概略的に表現している。本モデルでは、最終的な運動司令を生成するPremotor networkの中・長期的な適応調節系を主に担っているのが「小脳」であると考えている。この図は、様々な観測情報を運んでくる平行線維入力 (Parallel fiber inputs) と平行線維からプルキンエ細胞へのシナプス伝達効率の変化を誘発する登上線維入力 (Climbing fiber inputs) によって、小脳がそれぞれのレベルのPremotor networkのサイドパスとして抑制的に働く学習制御系を構成していることを表している。具体的には、入出力信号および経路が顕著に異なる小脳部位における運動調節系の例として、(1)小脳片葉による前庭動眼反射・視機性眼球反応、(2)小脳外側部による腕の随意運動、(3)小脳虫部・中間部による姿勢歩行制御、の各々の制御性の改善を、小脳皮質構造の一様性から連想される原理的に共通の学習スキームで説明しようとするものである。この統一学習スキ-

ムのための核となる考え方が前章で説明した「フィードバック誤差学習」である。そこで次節に、小脳運動学習とフィードバック誤差学習がどのように対応付け出来るかについて説明する。

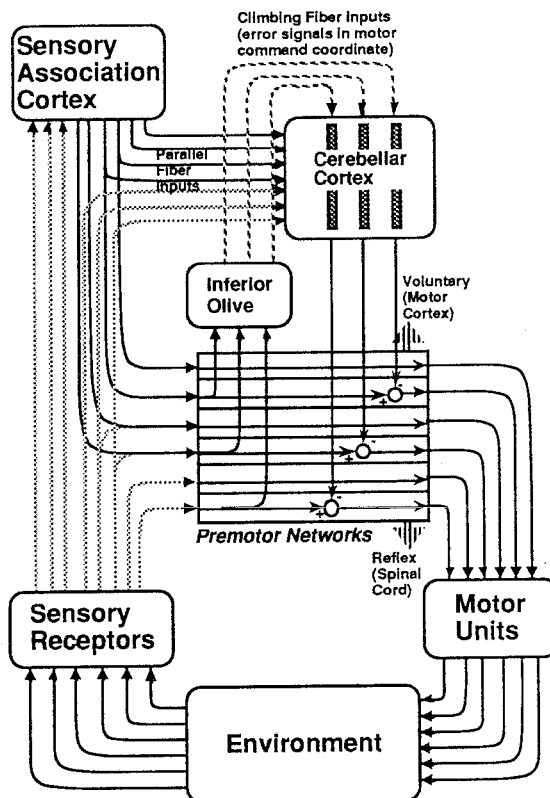


Fig.4.3 Schematic diagram showing how cerebellar motor learning might be incorporated in sensory-motor control.

Premotor networks are motor control networks that produce the motor commands from several signals such as sensory information and/or desired movement patterns.

4.3 小脳運動学習とフィードバック誤差学習

第3章で説明したフィードバック誤差学習で機能的に重要な点を振り返ると、フィードバック制御器の出力が運動結果から得られる「運動司令誤差」を近似的に表していることであった。すなわち、フィードバック制御器は「センサによってえられる誤差から運動司令誤差への誤差空間の変換」を行っているわけである。

さて生体系において、環境との相互作用によって生ずる様々な感覚受容器からの入力あるいは大脳皮質からの信号によって、複雑に絡み合った筋肉をうまく協調して円滑で正確な運動を実現するためには、複雑なキネマティクスやダイナミクスの問題を解いて個々の筋肉への運動司令が生成される必要がある。生体のキネマティ

スタクスやダイナミクスは成長などによって大きく変化し、また一定年齢までは成長と共に制御する機能は向上してゆくことから、この機能が生得的に備わっているとは考えがたく、むしろ学習によって獲得されてゆくものであることは想像に難くない。従来の医学的研究によって小脳がその機能の実現に大きく関わっていることが示されてきた^{28,29)}。ではその学習はどのように行われるのであろうか。

従来の小脳運動学習の仮説として、小脳プルキンエ細胞における信号伝達効率の変化をおこす下オリーブ核からの信号は「感覚情報の誤差」を表しているというものがある^{26,30)}。下オリーブ核は小さな領域ごとに限られた範囲の感覚受容野を持ち、その下オリーブが支配するプルキンエ細胞は特定の運動に影響を与えるニューロン群と結合している³⁰⁾。これは、上位からの信号に対してどこで誤差が生じたのかを検出し特定の筋に対しての運動司令を修正できるような仕組みになっていると解釈することが出来る。これに対し、プルキンエ細胞に平行線維を介して投射される情報は、1つの経路にさまざまな情報が含まれるもの(SRCT, VSCT, RSCT)、比較的受容野が限られるもの(DSCT, CCT)がある^{110,111)}。苔状線維から平行線維を介して入る情報は必要な情報を含んでさえいれば、誤差が減少するようにプルキンエ細胞で信号伝達効率が変わるわけであるから、受容野が区別されているものや融合した信号の中から必要に応じて情報は選択されると考えれば理にかなっている様に思われる。

しかし、異なる座標系での感覚入力と運動を考えた場合、単なる感覚誤差だけではそれを修正するためにどのように運動司令を修正したらよいのかは不明である。さまざまな感覚系からの情報が、運動の学習制御において有効に働くためには、下オリーブ核からの情報を、従来の仮説である「感覚情報の単純な誤差」として考えるだけでは不十分であり、運動司令誤差として考える必要がある。また、学習があまり進行していない段階では、感覚情報から得られた誤差を修正するように運動系を働かせることが行われ、工学的に換言すれば、ラフなフィードバック制御が行われていると言えよう。この運動結果を修正する運動司令信号は、3章で説明したフィードバック誤差学習のメカニズムの考察からもわかるように、運動司令を改善するための誤差信号として用いることができる。この信号が同時に、下オリーブ核から登上線維を通して小脳へシナプス荷重を変えるための信号として送られていると仮定すると、フィードバック誤差学習を学習原理とする小脳の学習スキームが考えられる。

以上の考察をFig.4.3で説明すると、すべての小脳部位 (Cerebellar Cortex) へ送られる登上線維信号(Climbing fiber inputs) が運動指令座標系での誤差を意味し、これはFig. 4.2に示したフィードバック誤差学習における、フィードバック制御器の出力に対応する。この誤差信号はFig.4.3に示されているように、運動司令を生成するPremotor network, すなわち脊髄・脳幹・大脳皮質運動野などの一部で生成される。Premotor networkの中にある特定の小脳深部核とつながる小脳皮質の各々のマイクロゾーン³⁰⁾では、運動司令誤差を表す登上線維信号によって平行線維とプルキンエ細胞の間の信号伝達効率が変わり、各運動系において必要な内部モデルを獲得する学習が行われる。「小脳への誤差信号が、各運動系における運動指令座標系で表されている」というフィードバック誤差学習の直感的解釈は、様々な運動に対する学習を統一的に説明する上で重要な点である。

次に、学習のための運動誤差信号を表しているモデルの中で考えている、下オリーブ核から登上線維を介して送られる信号の生理学的側面を振り返ってみる。この信号の入力の状態は、小脳プルキンエ細胞の出力信号の中の「複雑スパイク」と呼ばれる発火パターンを観察することによって調べることが出来る²⁶⁾。この発火は平行線維からの入力による「単純スパイク」と呼ばれる神経発火に比べて非常に頻度が低いため、その信号の定量的解析が困難であり、運動誤差の方向性や大きさを表していないと考えられていた。しかし、ウサギの小脳片葉では、網膜上の像のぶれ (retinal slip)が入力される下オリーブ核からの信号が運動司令誤差の方向性と大きさをコードしていることが生理実験データの統計的解析によって確認され⁹⁴⁾、またサルの手首の運動では、小脳外側部に投射する下オリーブ核の発火頻度が動作の習熟に従い減少して行く⁸³⁾ことが解明された。後述するように、歩行運動においても小脳虫部に送られる下オリーブ核からの信号は予想外の運動時に活性化されることが調べられた⁹⁵⁾。下オリーブ核からの信号が誤差を表現していることを示唆する生理実験結果を付録4-Fにまとめる。しかし、これらの生理学的データのみでは、誤差変換メカニズムの仮説を生理学的に積極的に支持しているとは主張するには不十分である。小脳への下オリーブ核からの信号が運動司令誤差に変換され表現されているかどうかを確認するためには、感覚誤差と運動誤差を人工的に変化させる様な実験系を組んで観察する必要があると考える。例えば腕の随意運動では、付録4-Bに述べるような、運動座標の変換の実験によって、複雑スパイク (すなわち下オリーブ核の発火) の様子がどのように変化するかを観察することにより誤差表現の座標系を

確認することが可能であろう。

以上、小脳での運動学習のフィードバック誤差学習としてのモデル化の枠組みについて説明したが、学習の共通性の発想は主に前庭小脳（小脳片葉）における眼球運動適応系のデータと4.4節で説明するそのモデル、および大脳小脳（小脳外側部）における随意運動学習系でのモデル⁹⁾に基づいている。脊髄小脳（小脳虫部・中間部）が強く関与する姿勢制御や歩行制御に関しては、その運動系の複雑さや実験の困難さのために、ハードウェアである神経回路と直結するような計算モデルを検討するのに必要な解剖学・生理学的データが十分得られてるとはいえない。また、歩行などの運動では非線形な現象を多く含むため、モデルもそれらの現象を説明できるよう工夫しなくてはならない。しかし、それらの運動における適応調節機構と小脳との関係は現象としては古くから知られており²⁹⁾、体幹制御に使われているとされる小脳虫部・中間部では、関与する神経回路の様子から主にフィードバック制御の適応系を構成していると考えられる。姿勢保持・歩行運動は不安定系であるため、フィードバック制御を必要とし、その制御特性を改善するためには、フィードバック制御の適応調節機構が要求される。これらの運動の小脳での学習モデルに、前庭動眼反射適応モデルおよび随意運動学習モデルでの考え方を拡張すると、第3章で説明したようなフィードバック制御系におけるフィードバック誤差学習を行っている可能性が考えられる。

それでは各論として、4.4節では比較的生理学的データも多く詳細なモデルの検討が可能で、4.5節では小脳虫部・中間部の姿勢・歩行運動系への関わりについての運動学的・生理学的知見をモデル化をする立場から整理し、フィードバック誤差学習に基づく学習系のモデルの可能性を考察する。

4.4 小脳片葉における眼球運動適応学習系

この節では、小脳片葉における眼球運動の適応学習系について考察する。始めに、前庭動眼反射(VOR)・視機性眼球反応(OKR)の適応系を構成する神経回路について説明する。次に、それらの適応系を「フィードバック誤差学習」の立場からモデル化し、そのモデルを用いたVOR、OKR同時適応のシミュレーションを示す。また、VOR適応調節に関する伊藤らの仮説に矛盾すると言われた生理データは付録4-Dで紹介する。

4.4.1 前庭動眼反射・視機性眼球反応適応系を構成する神経回路

前庭動眼反射 (VOR) ・視機性眼球反応 (OKR) の仕組みは、Itoら⁵⁴⁾やSimpsonら^{94,96)}、永雄⁹⁷⁾によって解剖学的・生理学的に調べられた。VORに関しては、小脳片葉における信号伝達効率の可塑性の仮説とあわせてそれらの反射運動の適応調節系がモデル化された^{26,90)}。これらのモデルでは、小脳は信号のゲイン調節器として働くと考えられ、これらの運動の小脳片葉での適応モデルと外側部での随意運動学習系のモデル⁹⁾との統一的な見方は明らかではなかった。

VOR・OKRに共通の目的は、網膜上に写る外界の像のぶれを少なくすることであると説明されている⁹⁸⁾が、VORでは眼球を頭部の回転と逆方向に同じ速度で回転させ像のぶれをおさえるものであるのに対して、OKRは外界の動きに対して目がつられて動くように反応して像のぶれを抑さえる。頭部の速度は前庭器官で計測され、網膜上の像のぶれは網膜で検出される⁹⁴⁾。




Fig. 4.4 Schematic diagram of neuronal circuit for horizontal vestibulo-ocular reflex and optokinetic response.

abducens nuclei:外転神経核, lateral rectus:外側筋, medial rectus:内側筋, oculomotor nuclei:動眼神経核, inferior olivary nucleus (IO):下オリーブ核, pretectal area:視蓋前域, vestibular nuclei (VN)::前庭核, left horizontal semicircular canal:左側水平三半器官

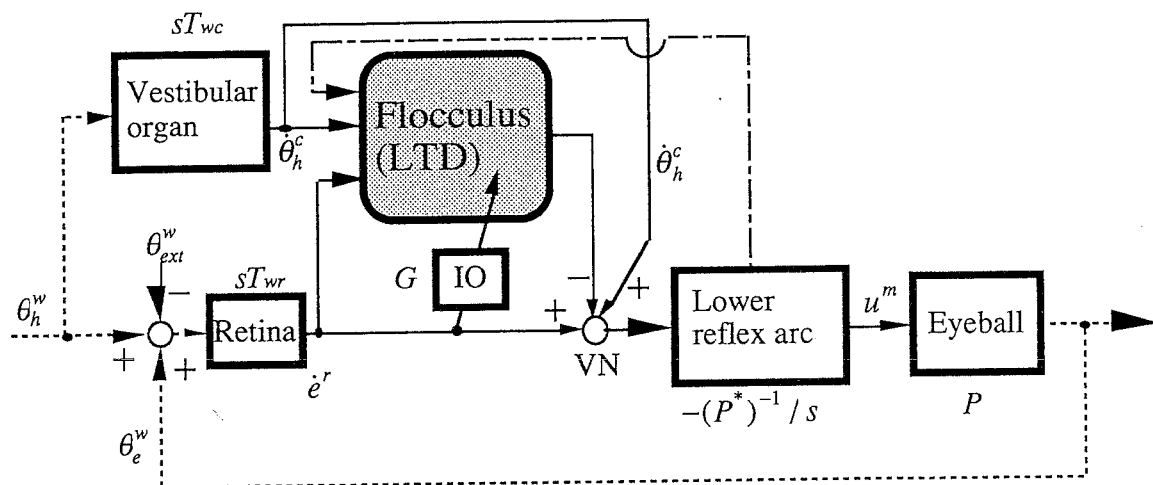
Fig.4.4に示すように、それらの反射系は数個の細胞を介して各々脳幹レベルでのフィードフォワード・フィードバック系を構成している⁹⁸⁾。これに加えて小脳は、VOR, OKRの精度を上げるためにサイドパスとして適応系を構成しており⁹⁷⁾、またその適応を起こすための誤差信号は下オリーブ核より供給される。

4.4.2 前庭動眼反射・視機性眼球反応適応系モデル

Fig.4.5に、Fig.4.4の前庭動眼反射・視機性眼球反応を起こす主神経回路とその適応的修飾を司る小脳を介する神経回路をブロック図にして表したものを示す。実線はFig.4.4に描いてある実際の神経回路に対応し、破線は信号の流れを示した経路である。図で各信号の記号に付く下付き文字は信号の種類（頭部、外界、眼球など）を表し、上付き文字は、信号を表す座標系を示す。頭の回転速度 θ_h^o は前庭器官（三半規管）で計測され、VNへの直接の経路と、片葉を経由してVNへ入る経路がある。網膜で検出されるRetinal slip e^r は、外界の速度 θ_{ext}^w 、頭部の速度 θ_h^w 、眼球の速度 θ_e^w の和として図の様に表すことができる。フィードバック誤差に相当するそのRetinal Slipの信号 e^r は、VNを通るフィードバック経路を構成すると同時に、下オリーブ核(IO)を通して小脳片葉にも伝達されている。先に述べたように生理学では、片葉が、VOR, OKR適応系を司っていることが知られている。さて、Fig.4.4からも判るように、この眼球運動適応系は第3章で考察したフィードバック誤差学習の学習適応制御モデルに似た形になっている。そこで以下に、この眼球運動適応系において、フィードバック誤差学習のポイントである誤差の座標変換（キネマティクス条件）とシナプス荷重（パラメータ）収束のための安定化（ダイナミクス条件）という計算論的観点から解剖・生理学的データを検討する。

眼球を動かす筋肉の座標系と頭部の動きを検出する三半器官の座標系は、眼球が前方に向かって付いている動物(frontal eyed animal)では特に異なっており⁹⁹⁾、そのため三半器官から運動司令への信号の座標変換モデル¹⁰⁰⁾などが提案されている。これらの眼球運動の適応系を構成するためには、下オリーブ核から小脳片葉へ送られる誤差信号が運動司令すなわち筋肉の座標系に変換されていないと計算論的には学習はうまく進行しない事になる。Simpsonら¹⁰¹⁾は、Retinal slipが送られるウサギ（ただし、これはfrontal eyed animalではなく、lateral eyed animalであるが）の下オリーブ核の発火（片葉での複雑スパイクの観察によって知ることができる）は網膜への刺激

の方向によってその強さが異なることを調べ、誤差信号座標系が筋肉の配置から得られる運動方向の座標系とほぼ一致することを確認した(付録4D参照)。これは、誤差信号が運動司令を修正できるように生体固有のメカニズムによって変換されていることを意味している。



- $e^r = sT_{wr}(\theta_e^w + \theta_h^w - \theta_{ext}^w)$
- $\dot{\theta}_h^c = sT_{wc}(\dot{\theta}_h^w)$
- retinal coordinate
- \equiv motor command coordinate
- \neq canal coordinate
- T_{wr} : transformation from world coordinate to retinal coordinate
- T_{wc} : transformation from world coordinate to canal coordinate
- θ_h^w : head position in world coordinate
- θ_{ext}^w : environmental (external seen) position in world coordinate
- θ_e^w : eye ball position in world coordinate
- e^r : retinal slip signal in retinal coordinate
- u^m : motor command
- P : eye ball dynamics
- P^* : approximated inverse of the eye ball dynamics
- VN: vestibular nuclei
- IO: inferior olive

Fig. 4.5 Block diagram of adaptive modification of vestibulo-ocular reflex and optokinetic response.

また、この系は閉ループ系の視機性眼球運動の適応系を含んでいるため、適応コントローラである片葉への下オリブ核への信号が単に制御対象の出力空間誤差から入力空間誤差に変換されたものであると考えるだけでは、理論的には学習系が安定に動作することが保証されない。言い替えると、単なる誤差の座標変換では出力

で検出された誤差を無限小にするためにゲイン無限大の方へ学習が進行することになる。遅れ要素の大きい生体系においてこれは学習の安定性が容易に崩れることを意味する。学習を理論的にも安定に動作させるには、(1)第3章で述べたように、出力の誤差を「逆規範モデル（出力誤差の収束に関しての規範的な応答の逆モデル）」を通してモータコマンドの誤差へ変換を行い、規範応答に従うとき誤差が0になるようにするか、あるいは(2)シナプス荷重に忘却項を加えることにより入力信号との間でパラメータを安定化をする、(3)パラメータ値にBoundaryを設けてパラメータの発散を防ぐ、などの方法が考えられる。いずれの方法がもっとも生理学的に確からしいか、あるいはこれら全ての要因が関わるのかは、今後より詳細なモデルを組み立てていく上での検討課題である。

以上のように、小脳片葉におけるVOR・OKRの適応機構は、まだ神経伝達物質がどのように作用しているかというメカニズムに関して未解明の部分もあるが、実際の神経回路の結合関係から各ニューロンの挙動まで多くの知見を従来の研究から得ることができる。そのために、それらの同時適応系は計算論のレベルまでそれほど大きな仮定を置くことなく整理することができ、その学習制御様式は、大局的には随意運動のモデルで用いられたフィードバック誤差学習⁹⁾の考え方によって理解できる。

4.4.3 前庭動眼反射・視機性眼球反応適応系のシミュレーション

次に、上で説明したモデルにしたがって、前庭動眼反射(VOR)・視機性眼球反応(OKR)の適応を同時に行ったシミュレーションの結果を示す。このシミュレーションの実際の運動実験に相当するものは、Fig.4.4に示したようなもので、頭部回転と外界の動きを表示するためのドラムの回転によって構成される。このようなセットアップは、実際ウサギやサルを使った実験で使われている。ここでは学習のダイナミクスだけを考察するためにモデルを単純化し、眼球は式(4-1)で表せる線形の2次の質量粘弾性系であるとし、水平系1自由度のみの動きを考える。

$$M_e \ddot{\theta}_e + B_e \dot{\theta}_e + K_e \theta_e = u \quad (4-1)$$

ここで、 $\ddot{\theta}_e, \dot{\theta}_e, \theta_e$ は各々眼球の加速度、速度、位置で、 u は運動司令を表す。係数は、

実際に調べられた眼球運動細胞と眼球運動の関係を表す係数の平均値¹⁰²⁾に比例させ、入力を無次元として、それぞれ、

$$\begin{aligned} M_e &= 6.4 \times 10^{-6} [1/(\text{rad}/\text{sec}^2)] \\ B_e &= 4.0 \times 10^{-4} [1/(\text{rad}/\text{sec})] \\ K_e &= 2.2 \times 10^{-3} [1/\text{rad}] \end{aligned} \quad (4-2)$$

と設定した。小脳片葉に相当する適応コントローラの部分は、ブロック図に示されているように、Retinal slip, 頭部速度, 運動司令の内部フィードバックの3つの入力を持ちそれぞれに適応ゲイン (シナプス荷重) が掛けられた後, 加算されて運動司令の一部になる。そのシナプス荷重 w は, 下オリーブ核から送られるRetinal slipの信号を減少させるように, かつ学習の安定化のための忘却項を入れ, 式(4-3)に従って調整した。

$$\frac{dw}{dt} = -\frac{1}{T}w + \eta e \quad (4-3)$$

ここで, T は忘却の時定数, η は学習速度係数である。

またシミュレーションでは神経系の遅れに相当する時間として, 運動司令の片葉への内部フィードバックに10[ms], retinal slipの信号処理と伝達時間として20[ms] のむだ時間を加えた。シミュレーションのための積分は4次Runge-Kutta法を用い, $\Delta t = 2 \times 10^{-4}$ [sec]として行った。

さて, Fig.4.6は学習初期の, 眼球, 頭部, 外界 (ドラム), retinal slipが零になるときの眼球の位置 (目標位置), の軌道である。学習中, 外界は0.2[Hz] 0.4[rad](peak to peak)で動かし, 頭部はランダムに動かした。Fig.4.7は学習中の, 各入力に対するシナプス荷重の変化である。シナプス荷重は初め0の状態から変化し, 平衡状態に落ち着いている。このパラメータが発散しないのは式(4-3)のシナプス荷重の忘却項の効果である。Fig.4.8は学習中のretinal slipと片葉出力に相当する信号の各々の自乗移動平均を示す。学習時間が経つにつれ, 片葉出力が増加し, retinal slipが徐々にではあるが減少している。

学習後のVOR, OKRの結果は, Fig.4.9の様になる。VOR, OKRとも頭部の動き, 外界の動きに対する反応がよくなっているが, 正確にはretinal slipを完全にキャンセル

するような結果にはなっていない。これは、ウサギの生理実験の結果に適合するように忘却係数の大きさや学習時の入力大きさなどを設定したためである。原理的にはVORは頭部の動きを検出し反対方向に眼球を動かすという前向き制御であるため、3章の非線形レギュレータ学習(NRL)で考察したようにretinal slipを漸近的に0にすることは可能であり、OKRの様な反応についても工学的にはより追従性を上げることは十分可能である。




Fig. 4.6 Time courses of eye, head, external world and desired eye position during learning.




Fig. 4.7 Time courses of the gain parameters for each flocculus input (i.e., head velocity, retinal error and feedback motor command) during learning simulation.




Fig. 4.8 Time courses of the moving averages of the squared retinal error and the squared flocculus Purkinje-cell output during learning simulation.

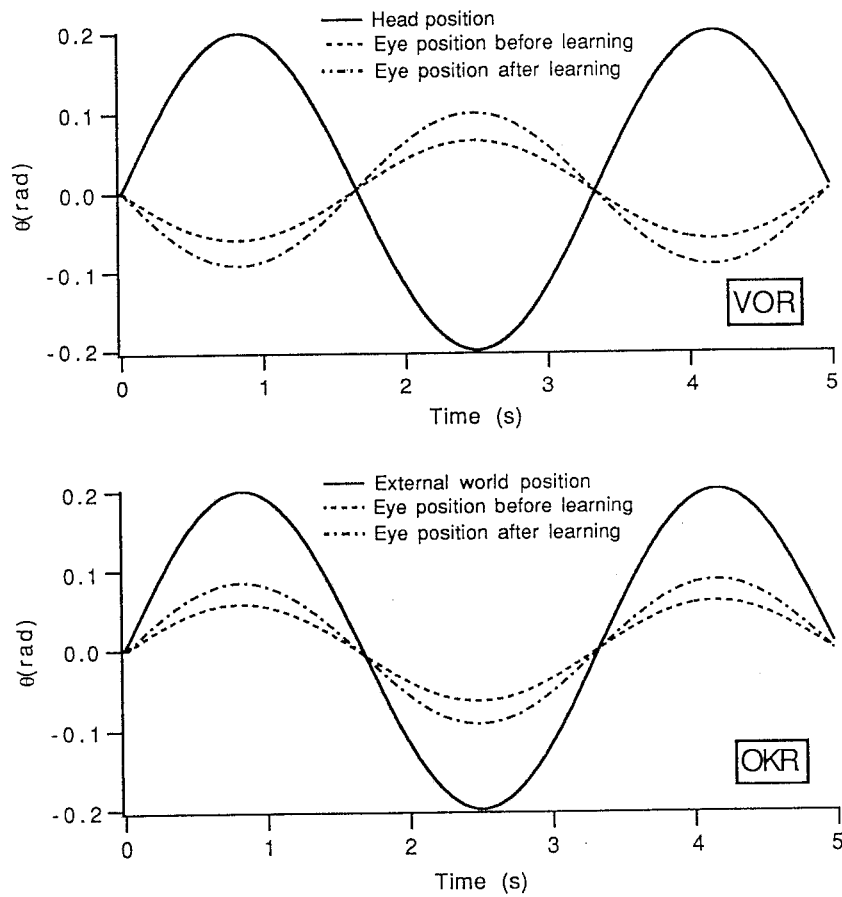


Fig. 4.9 VOR responses and OKR responses (i.e., eye position responses for sinusoidal head movement and external world movement) before learning and after learning.

4.5 小脳虫部・中間部における姿勢・歩行制御学習系

Table 4.1 に示したように小脳虫部・中間部は、脊髄小脳として機能分類され、以下に述べる姿勢・歩行制御ばかりではなく様々な末梢運動制御系に関わっている。ここでは、小脳皮質構造の一様性から連想される「共通の学習原理」と、入出力関係によって発生する「学習系の機能分担」という視点から、これらの部位における学習を考察するために、フィードバック制御を必要とする運動の代表例として姿勢制御を、フィードバックとフィードフォワード両制御が必要だと考えられる基本的な運動の代表例として歩行制御を取り上げる。

従来、姿勢制御や歩行制御の研究は、制御理論的・現実的に歩行機械を動作させることを目標とする、あるいはそれを実現することでバイオメカニズムの視点からこれらの運動を理解しようとするアプローチ¹⁰³⁾と、生理学的な神経機構の動作を明らかにしてこれらの運動を理解しようとするアプローチ^{104,106,108,110)}に2分される。前者のアプローチはかなり整理されてきており、実際に2足歩行ロボットを動かすまでに進展している¹⁰³⁾。一方、後者の神経機構の動作原理を解明することにより歩行運動を実現しようとするアプローチは、多くの神経活動の現象と運動との関連が観察されているにもかかわらず、脳がそれらの動作に対し複雑に関わっているために、システムとして動作する全体的なモデルが描かれるまでに至っていない。また前者のアプローチとの間には大きな溝があり、「制御理論的アプローチで考えられた計算原理が、実際の脳でも行われているか」、「行われている必要があるとすれば、脳のどこで計算されているのか」などの対応関係はほとんど明らかになっていない。

後述するように、それらの運動に対しては小脳虫部・中間部が重要な役割を果たしていることが知られている。そこでこの節では、それらの運動の小脳での学習系を考えるために、まず4.5.1で姿勢・歩行制御と小脳との関わりについて述べる。次に4.5.2で、姿勢・歩行制御に密接な関わりを持つといわれている小脳虫部・虫間部の神経回路について説明する。そして、川人らの提案した小脳外側部における随意運動学習系のモデル、および前節で示した小脳片葉における眼球運動適応系のモデル、とのアナロジーおよび運動学的知見を踏まえ、4.5.3で小脳虫部・虫間部における姿勢・歩行制御の学習をフィードバック誤差学習法を用いて説明する概念的なスキームを提案する。

4.5.1 姿勢・歩行制御系と小脳の関係

人間は支持面積に比べてかなり高い位置の重心を2本の足で支える不安定な状態（直立姿勢）の保持が可能である。これが可能なのは、現在の状態を逐次観測し修正動作を掛けるフィードバック系を有しているためである。そしてこの能力は、とりわけ人間においては、生後の成長過程において学習することによって獲得される。小脳と姿勢制御の適応系との関係は古くから知られている。例えば、腱や筋の深部感覚受容器からのフィードバック入力断たれた時に、姿勢保持が安定にできなくなるというRonberg徴候等にみられる制御性の劣化が他のセンサからの入力で補われる適応機構がある¹⁰⁶⁾こと、あるいは小脳を損傷した患者は姿勢制御における適応機構が著しく劣化してしまうこと¹⁰⁷⁾などがある。

また歩行などのリズム運動においては中枢神経系にある神経発振器 (Central Pattern Generator, CPG) が重要な役割を果たす（付録4-F参照）ことが知られているが、小脳と歩行運動との関係についても、次のような幾つかの実験結果が示されている。除脳ネコ（小脳あり）は中脳歩行誘発野（楔状核）の刺激に応じて歩行運動を行うことができる¹¹⁰⁾が、小脳虫部あるいは中間部の特定部位を冷却したとき歩行時の協調動作に障害が発生する⁸⁵⁾。また、虫部の出力細胞であり体幹の筋肉を制御するDeiters核の応答が歩行のフェーズとよく一致する¹⁰⁸⁾。Frossbergら¹⁰⁹⁾も脊髄ネコを使った実験で外乱に対する肢間の協調動作が障害を受ける事を示している。

これらの結果からも、小脳が姿勢・歩行運動においても重要な役目をはたしており、小脳の計算モデルを構築してゆくには、これらの運動制御における小脳の役割と学習メカニズムを明らかにしてゆくことが必要である。

4.5.2 小脳虫部・中間部における神経回路の構成

小脳虫部プルキンエ細胞は、Table 4.1 で示したように主に脊髄・視聴覚・前庭からの入力を平行線維を介して受ける。小脳深部核の1つである室頂核を介しての出力の最終目標は脳幹・運動野になっている。機能としては、体幹の姿勢保持が挙げられている。この部位における神経回路の構成の様子をFig.4.10(a)に示す。脊髄から小脳に情報を送る経路(SCT)は固有感覚受容器(Proprioceptors)の情報を主に含み、四肢(Limbs)や体幹(Body Trunk)の位置・速度・力を伝達している。前庭器官からの経路は頭部の速度・加速度及び傾きを、視覚・あるいは眼球からの経路は速度・位置

の情報を主に送る。虫部プルキンエ細胞は平行線維を介しての大脳皮質からの投射は見られず、フィードバック情報に対しての適応系を構成していると考えられる。

小脳中間部の神経回路も解剖学的生理学的にある程度調べられてる。しかし、歩行運動のリズムを与えられていると考えられている¹¹⁰⁾視床下核歩行誘発野や中脳歩行誘発野などとの関連が明確ではなく、より詳細な結合関係や信号の伝達に関する知見が待たれる。Fig.4.10(b)に塚原らの研究⁹¹⁾に基づく中間部での神経回路網の様子を示す。この部位が外側部や虫部と大きく異なるのは、この部位のプルキンエ細胞がFig.4.10(b)に示すように大脳皮質からの信号 (cerebral cortex->PN->PC経路) と固有受容器・前庭器官・視覚などの感覚フィードバック信号 (SCT経路) の両方を平行線維を介して受けるという事である。このことは、この部位がフィードフォワードとフィードバックの両方の制御系の学習に関わっている可能性を示唆している。




Fig. 4.10 (a) Schematic diagram of neural circuit of posture control in vermis.

SCT: Spinocerebellar tracts (VSCT, DSCT, CCT, RSCT, SRCT), CRST: Cerebelloreticulospinal tract, CVST: Cerebellovestibulospinal tract, SOCPs: Spino-oligo-cerebellar paths, CF: Climbing fiber, MF: Mossy fiber, FN: Fastigial nucleus, IO: Inferior olivary nucleus, VL: Ventrolateral nucleus of thalamus, PC: Purkinje cell, ST: Stellate cell, GO: Golgi cell, BC: Basket cell, GR: granule cell.

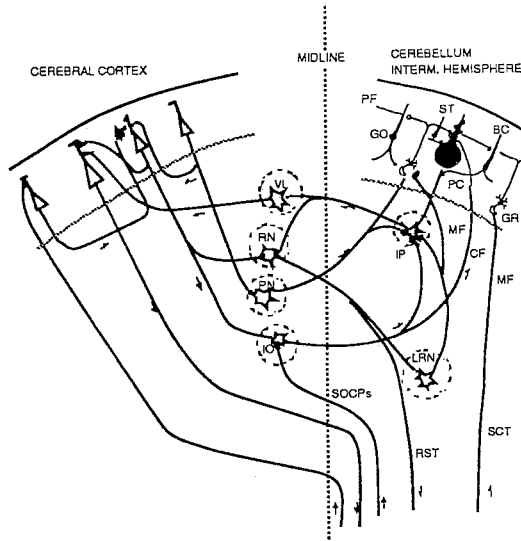


Fig. 4.10 (b) Schematic diagram of neural circuit in intermediate part of hemisphere.

RST: Rubrospinal tract, IP: Interpositus nucleus, PN: Pontine nuclei, RN: Red nucleus, VL: Ventrolateral nucleus of thalamus, LRN: Lateral reticular nucleus.

4.5.3 フィードバック誤差学習に基づく姿勢・歩行制御学習系の概念的スキーム

次に、以上に説明した虫部・中間部における姿勢・歩行制御の学習適応系のモデルを考える。小脳皮質構造の一様性から連想される「共通の学習原理」を基に、前庭動眼反射適応モデルおよび随意運動学習モデルでの考え方をこれらの運動学習系モデルにも拡張すると、下オリーブ核からの情報が「運動司令誤差」を表す信号になっているというアナロジーが発想される。すなわちFig4.11(a)(b)に示す様に、高次中枢からの信号と感覚器からの求心性信号によってどこの受容器に誤差が生じているのかを検出し、フィードバック制御器に相当する誤差変換のメカニズムによって、どこのモータユニット（筋肉）への運動司令がどの程度間違っていたのかを表わす運動司令誤差へ変換され、その誤差が下オリーブ核から小脳へ送られるというスキームを想定するということである。

小脳虫部・中間部に投射する下オリーブ核からの信号が、小脳片葉や外側部へ投射する下オリーブ核の信号と同様に、誤差を表しているという仮説を支持する実験データは、Gellman¹¹²⁾やMatsukawaら⁹⁵⁾によって示された。Gellmanはネコを使った実験で、下オリーブ核は受動的な運動によっては発火するが、能動的な運動によって

は発火しない事を確認している。Matsukawaらもネコを用いた実験で、定常的な歩行が外乱によって乱されたとき虫部のプルキンエ細胞に複雑スパイク（登上線維入力が入ったとき発生する）が発生することを確認している。

多くの生理学データから、姿勢・歩行制御において小脳虫部中間部がその適応機構を担っていることがほぼ確実であることは知ることができるが、望ましい運動規範からの運動司令誤差が下オリブ核を通して与えられ学習が行われるという仮説を裏付けるのには十分ではない。今後、このような複雑な系では、単に現象を観察するだけの生理実験ではなく、いままでより一層計算論に基づいて生理実験の組立をしてゆくことが重要であると考ええる。

一方、制御メカニズムとしての合理性の側面を考えて見ると、姿勢・歩行制御も不安定系であるため閉ループによる制御が必要である。歩行制御が姿勢制御と異なる点は、姿勢制御の際は目標とする平衡点がある姿勢を保とうとするとき変化しないのに対し、歩行制御では時々刻々と変化する事であり、随意運動の制御に近い面を持っていると言えよう。すなわち歩行運動は、フィードフォワード制御とフィードバック制御の両方を行うことによって実現されていると考えられる。

以上のような解剖・生理学データと計算論的合理性および小脳の他の部位での学習とのアナロジから、Fig.4.11(a)(b)のような姿勢・歩行のための適応制御系の概念的スキームを考えた。(b)の歩行制御系では、発振系と反射系、脊髄、下オリブ核までが複数の足での協調動作まで含めた歩行の誤差変換メカニズムを構成する。実際の歩行における速度に応じた不連続なパターン変化は、その規範モデルが歩行速度に適したパターン変化をするために起こると考える。そして実際の制御時に運動誤差が生じたとき下オリブ核からシナプス荷重を調整する信号が発生する。誤差変換メカニズムを通して生成される運動司令誤差が減少するように学習は進行し、誤差がなくなったとき、あるいは学習の平衡状態に落ち着いたとき、学習は飽和する。今後、この運動司令誤差を生成するメカニズムをどのように構成すれば合理的なのか、あるいはそれ自体も学習で作られると考えるのが自然なのか、姿勢制御や歩行に適した内部モデルとはどんなものか、などを考えてモデルをより明確にしてゆくことが必要であろう。

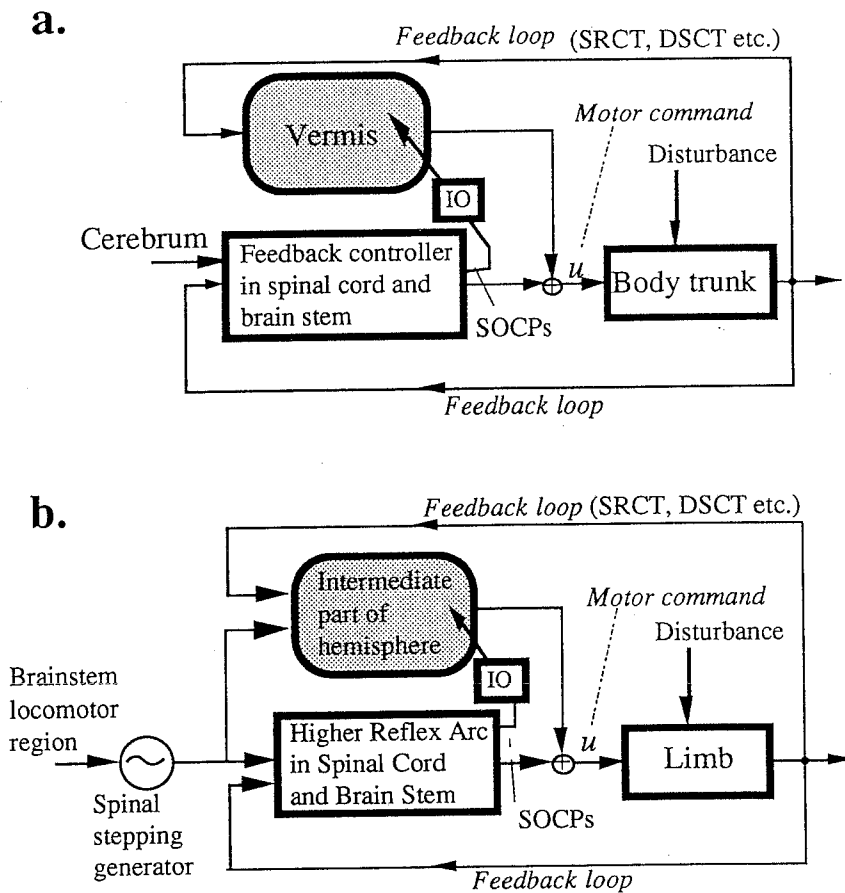


Fig. 4.11 Schematic block diagram for learning mechanisms of (a) posture control in vermis and of (b) locomotion control in intermediate cerebellum based on feedback-error-learning, which are associated by the modeling of voluntary movement learning mechanism in lateral cerebellum and of VOR/OKR adaptation mechanism in flocculus.

4.6 まとめ

本章では、生理学的・解剖学的研究成果と計算論的な考えを基本に、フィードバック誤差学習の考え方によって、一様構造を持つ小脳において各部位に対応する学習適応制御系モデルが構成できることを示した。しかし、虫部・中間部の学習モデルは生理学的・解剖学的に調べられている部位や複雑に絡み合った経路がモデル中のどの要素のどの信号に対応するのかという明確な対応づけは現段階では困難であり、前庭動眼反射のように明快に説明できていない。特に歩行制御学習系においては、肢間の協調動作を考慮した運動司令誤差はどのように生成されるのか、あるいはその誤差信号生成が実際の信号経路でどう実現されているのか、などの問題に対して上記の概念的なモデルでは説明が不十分であり、今後、計算論と生理学の両観点からさらに調べる必要がある。

第5章

小脳神経活動の解析

本章では、眼球運動中の小脳神経活動とその時の眼球運動の関係を定量的に解析することにより小脳がどのような情報を出力しているのかを明らかにする。解析には線形逆ダイナミクス表現を用い、小脳出力細胞であるプルキンエ細胞の活動を眼球運動の位置・速度・加速度の情報から再構成した結果を示す。

5.1 はじめに

前章では、さまざまな制御対象の内部モデル（近似逆システム）を学習により個々に獲得し、それを使って四肢や眼球を制御しているという”運動学習制御のための小脳計算モデル”を提案した。この考え方は、藤田^{90,27)}の「小脳適応フィルタモデル」、伊藤らによる「前庭動眼反射適応系のための小脳片葉プルキンエ細胞におけるシナプス可塑性」の仮説と生理学実験^{26,113,114)}、川人ら⁹⁾による「小脳外側部における逆ダイナミクスの獲得のモデル」を発展させたものである。

さて、このモデルを生理学的に検証してゆくためには、小脳出力が運動にどのように関わっているのか、小脳でどのような信号の変換が行われているかを実際のデータから正確に調べなければならない。しかし、運動の過渡的な状況での小脳プルキンエ細胞 (P-cell) の神経発火やその入力を精度よく定量化することは非常に困難であり、「ゲイン調節器」^{26,27)}の考え方を発展させた「内部モデル（逆システム）制御仮説」に対して実際の生理学データによる定量的な考察は従来示されていなかった。

河野・設楽ら^{115,116,117)}は、視野全体の動きにつられ眼球がその方向に動く「追従眼球運動」(Ocular Following Response) という反射系眼球運動に着目し、その運動に関与する脳部位 (MST (medial superior temporal area), 橋核背外側部DLPN (dorsolateral pontine nucleus), 小脳傍片葉腹側部VPFL (ventral paraflocculus), Fig.5.1(c)参照) の神経活動を調べている。それらの研究では、呈示した視野を静止状態から一定速度で動かすことを繰り返し行い、同じ条件下でのデータを多く取り、それらをアンサン

ブル平均し、神経発火頻度と過渡的な運動との関係が定性的に調べられた。

そこで本章では、それらの解析を一步進め、「内部モデル（逆システム）制御仮説」を検証して行く一步として、小脳プルキンエ細胞の発火頻度が何を表現しているかを定量的に明らかにすることを試みる。具体的には、Shidara & Kawano¹¹⁷⁾の実験によって得られたサルの追従眼球運動時の小脳傍片葉腹側部プルキンエ細胞の発火パターンを、線形逆ダイナミクス表現を用いて再構成した結果および考察について述べる。

5.2 実験条件と解析データ

本章で用いる実験データは、Shidara & Kawano¹¹⁷⁾による電気生理実験によって採られたものである。以下にその実験の概要を簡単に説明する。Fig.5.1(a)に示すようにミラー・ガルバノメータを使ってランダムドットの視覚刺激をサルに見せ、スポット光により視線を視覚刺激の中心部に動かさせ静止させた後、視覚刺激（ランダムドットパターン）を4方向（上下左右）のうちそのP-cellがよく反応する方向（preferred direction¹¹⁷⁾）に一定速度（10, 20, 40, 80, 160 [deg/s]）で動かし、一定時間サルに呈示する。視覚刺激を動かすと眼球はその動きにつられて動くが、その運動の発現に関わる神経回路はFig.5.2の様に整理されている。実線の矢印が生理学的に確認されている経路で、点線は存在が不確かなもの、あるいはその寄与がよく判っていないものである。図から判るように、小脳傍片葉(VPFL)は眼球を動かすための最終出力である眼球運動細胞に近い。小脳活動を観察する実験では、眼球の位置をFig.5.1(b)に示すようにサーチコイルにより、また小脳傍片葉腹側部(VPFL)(Fig.5.1(c))の単一神経細胞の発火を微小電極により、刺激呈示の間同時に記録する。眼球位置・速度の信号は6次のベッセルフィルタ (cut off 100 [Hz]) でノイズを除去され2[ms]ごとに、また神経発火(simple spike)はTime-amplitude window discriminatorでフィルタリングされた後1,0信号として1[ms]ごとに記録されている。




Fig. 5.1 (a),(b) Configuration of the experiment.
 (c) Activity recording site, VPFL (ventral paraflocculus).

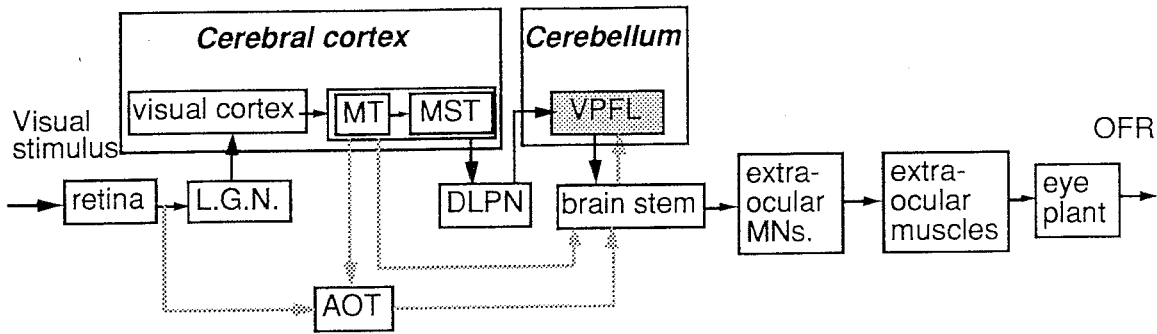


Fig. 5.2 Main pathway for generating ocular following responses.

神経発火頻度*と運動**との時間パターンを観察するため、記録された同じ条件のデータ組（11回から194回(平均97.0回)のトレースを含み、saccadeなどによって途中から状態が大きく変わったものは除いた）を、刺激開始時点をそろえて各々アンサンブル平均した。また各信号に含まれる遅れ要素を等しく扱いかつ各データ組に含まれるトレース数の大小によるノイズの影響の差を押さえるため、平均後の神経発火頻度を運動信号と同じ特性のフィルタで平滑化した。ここで、2[ms]毎のデータになっている位置・速度のデータは零次ホールドでデータを補間して1[ms]毎のデータとし、加速度の信号はアンサンブル平均後のデータを3点数値微分することにより求めた。解析には、preferred direction¹¹⁷⁾を運動の正方向に取り、その方向に5種類の刺激移動速度、数種類の刺激呈示時間で刺激を与えた時の、25個のP-cellの発火頻度と眼球運動が記録されたデータ94組を用いた。ただし、実験の都合により各P-cellに対し全ての刺激移動速度、呈示時間の条件でのデータは採取されていない。Fig.5.3-に解析に用いたデータの一例を示す。

* 神経発火頻度は、その時刻に神経発火が発生する確率を表しており、一般的に[spike/s], [impulse/s]で表される。

**眼球運動の研究では、一般的に眼球の回転角度の単位として[deg]が使用されており、本章ではこの単位を使用する。なお、1[deg] = 0.01745[rad]




Fig. 5.3 Ensemble averaged data of 194 trials in same stimulus condition. From top to bottom, visual stimulus velocity, P-cell firing frequency which was observed in a single Purkinje cell, eye angular acceleration, eye angular velocity and eye angular position.

5.3 解析手法

眼球運動は神経細胞1つの発火により起こるわけではなく、同時にいくつもの細胞、いくつもの経路からの信号により駆動されるため、1つのニューロンの発火だけから因果性を満たすモデルを構成することは不可能である（本章考察参照）。そこでここでは、因果性を要求しないモデルとして神経発火頻度を式(5-1)で表される逆ダイナミクス表現により再構成することにより、発火頻度の中に含まれる運動の各成分（位置、速度、加速度）との相関を観察する。

$$\hat{f}(t - \delta) = M\ddot{\theta}(t) + B\dot{\theta}(t) + K\theta(t) + f_{bias} \quad (5-1)$$

上式で、入力 $\ddot{\theta}(t)$ 、 $\dot{\theta}(t)$ 、 $\theta(t)$ は、各々時刻 t での加速度、速度、位置を、出力

$\hat{f}(t-\delta)$ は、モデルによって再構成される時刻 $t-\delta$ における神経発火頻度を表す。それらの係数 M, B, K , 発火から運動までの潜時差*に相当するタイムラグ δ , および $0[\text{deg}]$ で静止したとしたときの仮想的な発火頻度に相当するバイアス f_{bias} は、実際の発火パターンと再現される発火パターン（すなわち式(5-1)の左辺）の推定二乗誤差が最小になるよう推定する。実際のバイアスの神経発火頻度が負になることはないが、観察している細胞の神経発火頻度の位置成分がどの眼球角度で最低になるかが不明、すなわち位置のオフセットが不明なため、バイアス f_{bias} が負に推定されることもある。潜時差の推定では、小脳から眼球までの神経伝達時間が $10[\text{ms}]$ 程度であることを考慮し、潜時差の探索範囲を $-20[\text{ms}]$ から $20[\text{ms}]$ に限定した。

5.4 解析結果

上記の手法は線形解析であるため、解析対象の非線形性などの影響により、同一のP-cellでも刺激速度や刺激呈示時間などの条件を変えた場合各推定係数が各々のケースで異なる。そこで、5.4.1では条件が異なるものはすべて独立と考えて各条件（P-cell, 刺激速度, 刺激呈示時間）毎に線形モデルの係数を求める解析を、5.4.2では同一P-cellで取られた別の刺激速度・別の刺激呈示時間のデータをすべて使い1組の線形モデルの係数を求める解析の両方の結果を示す。

5.4.1 条件別のデータによる解析

(1) データの選択

5.2で説明したデータ94組に対して、式(5-1)を発火頻度について最小二乗誤差を満たすように各係数を求める。

次に、線形モデルへの適合度を表す指標として一般的な、式(5-2)により求められる「決定係数」 R^2 を用い、ここで使用したモデルにより説明可能なデータの選択を行う。

*「潜時」は、刺激の入力から観測地点での刺激による現象の変化が起こるまでの時間で、ここで言う「潜時差」は、（「視覚刺激から運動変化発現までの時間」—「視覚刺激から細胞発火変化発現の時間」）を指す。

$$R^2 = 1 - \left(\frac{\sum_i (\hat{f}(t) - f(t))^2}{\sum_i (f(t) - \bar{f})^2} \right) \quad (5-2)$$

ここで、 $\hat{f}(t)$ は式(5-1)により再構成されるP-cell発火頻度、 $f(t)$ は計測した同じ条件下での発火頻度のデータをアンサンブル平均したもの、 \bar{f} は $f(t)$ の時間平均を表す。Fig.5.4に全てのデータ組に対する決定係数のヒストグラムおよびquantile box plotを示す。決定係数が0.7以上のものは全体の70.2%(66/94)であった。また、付録5-Aに示すように、各データセットを作った元のデータのアンサンブル数と決定係数にはそれほど強い相関が見られなかった。これは、アンサンブル数の違いに起因するノイズ成分の分散の大きさの違いが与える決定係数への影響が、5.2で説明したフィルタの効果により減少されているためと考えられる。





Fig. 5.4 Histogram and quantile box plot of coefficient of determination.

Explanation of a quantile box plot:



さらに、推定された潜時差 δ の信頼性を確保するため、次のデータ撰択を行った。先に説明したように、 δ は-20[ms]から20[ms]まで探索するため、各 δ に於て、決定係数が求まる。そこでまず、各データに対する決定係数と δ との関係から、決定係数が最大になる δ を時刻0にとり、その決定係数の値を0として原点を変更した関係を作る。次に、その原点から指定時間幅の間で決定係数があまり下がらないもの、すなわちその時間幅の中でモデルへのフィティングの度合いがほとんど変化しないものは、解析対象から外すような選択基準を設定した。本解析の場合、この時

間幅を ± 3 [ms] とし, この間に決定係数が下がる基準を 0.002 として選択を行った. Fig.5.5(a) は決定係数が 0.7 以上の各データ組に対し決定係数と δ を決定係数の最大値の点で 0 とした関係を重ね書きしたグラフで, Fig.5.5(b) は原点付近の拡大図である. 点線は, 上記の選択操作によって落とされた 9 組のデータである.

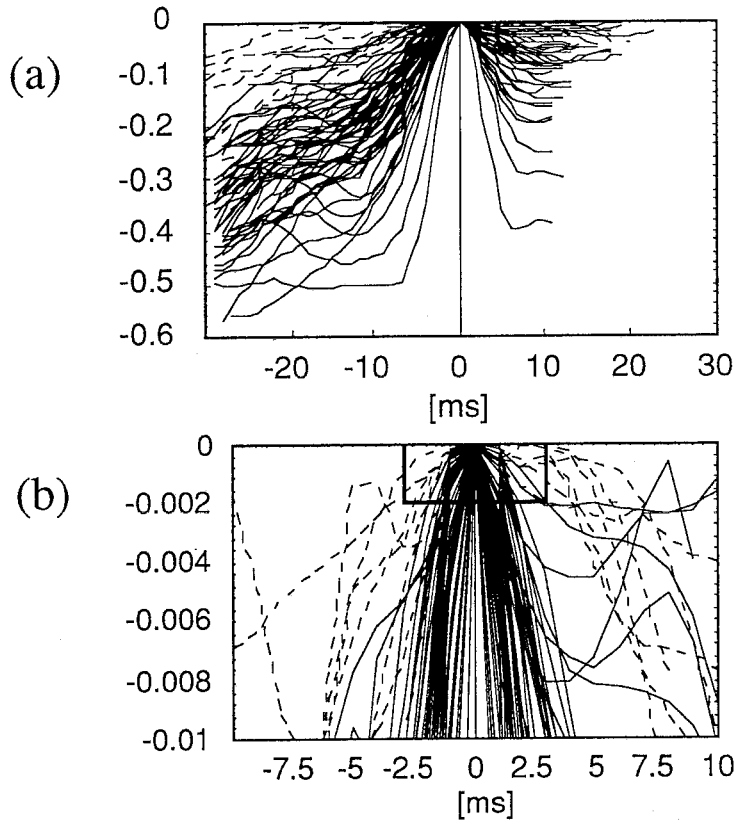


Fig. 5.5 The relation between relative coefficients of determination and relative time lag, δ , of data sets whose coefficient of determination at the maximum point were over 0.7.

(a) The origin of horizontal axis in each case was shifted to the time when a coefficient of determination was maximum in the observed range, and the origin of perpendicular axis was shifted to the maximum point of coefficient of determination in each case. The relations of all case indicated as a line were superimposed in this graph. Dashed lines denote the excluded case by the selection. (b) Magnified view at the origin of upper graph. The thick line denote the selection-window for dropping the data sets for which parameters might not be properly estimated.

以上の 2 つの基準によって選択された, モデル化精度がよく, かつ推定潜時差に信頼性が得られるデータ 57 組を, 以下の解析の考察の対象とした.

(2) プルキンエ細胞発火パターンの再構成

推定された係数と潜時差を用いて、式(5-1)により再構成されたP-cellの発火パターンの一例を実験で得られた平均発火パターンと比較してFig.5.6(a)に示す。また、Fig.5.6(b)には、発火頻度に占める運動の各成分、即ち式(4-4)の $M\ddot{\theta}$, $B\dot{\theta}$, $K\theta$ と f_{bias} に分解したものを示す。

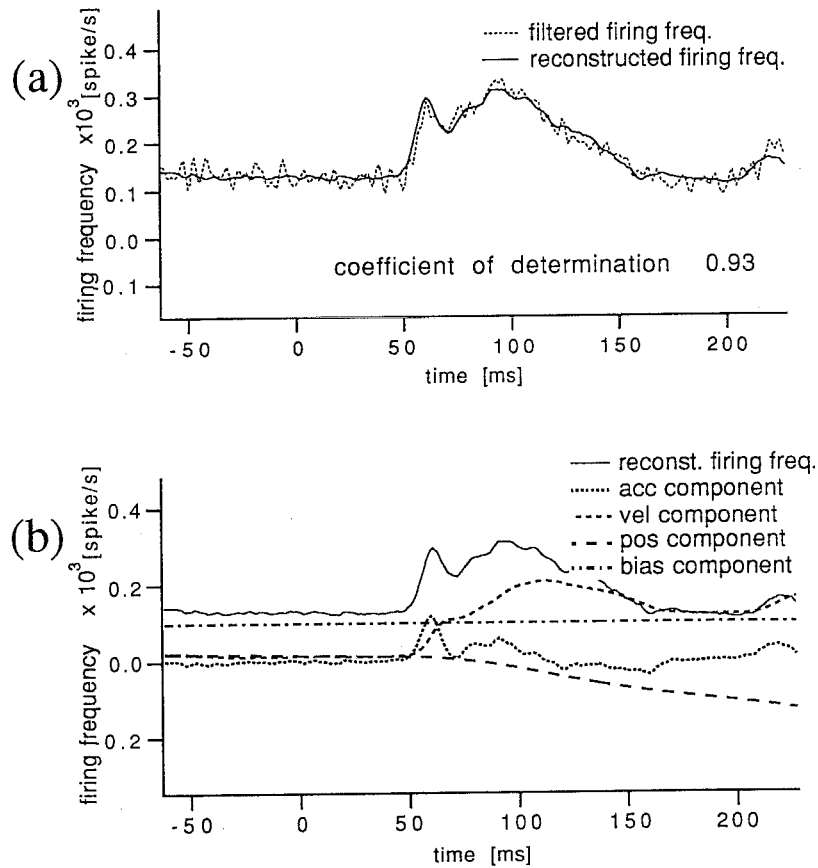


Fig. 5.6 (a) Reconstructed and observed VPFL P-cell firing pattern. (b) Components of reconstructed firing frequency ascribed to eye angular acceleration, angular velocity and angular position.

Fig.5.6(a)が示すように、発火パターンは推定係数を用いて精度よく再構成されており、式(5-1)による逆ダイナミクス線形モデルがこの運動中のP-cell発火の解析に有効であることが判る。また、発火の立ち上がりの部分では、加速度成分を多くコードしており、時間が経つにしたがい、速度・位置の成分の比率が高くなってきている様子がFig.5.6(b)より判る。しかし、どの時刻においても、完全に1つの成分で発火頻度が構成されているわけではなく、時間と共に成分比が変化しながら出力されて

いる。これにより、この様な過渡的な運動において、ある区間だけを取りだして速度や加速度に対する発火頻度の感度を計算する従来の方法¹¹⁸⁾を用いることはできないことが判る。

P-cell発火頻度を良く再構成できる（決定係数0.7以上）データにおける推定潜時差 δ のヒストグラムおよびquantile box plotを Fig.5.7に示す。 δ の推定値は平均6.93 [ms] (± 2.95 S.D.)で、対象としたデータ組のうち61.4%(35/57)が8-11[ms]となり、細胞を電気刺激することにより観察された電気刺激から運動変化発現までの潜時¹¹⁶⁾ (8.6-10.9[ms])とも近い値になるケースが多くあった。この結果は、ここで解析したプルキンエ細胞の活動が追従眼球運動の発現に強く関与していることを支持するものである。




Fig. 5.7 Histogram and quantile box plot of estimated time lag.

次に、推定された加速度・速度・位置の係数およびバイアスのヒストグラムおよびquantile box plotを Fig.5.8に示す。各係数の平均は $0.0709[(\text{spike/s})/(\text{deg/s}^2)](\pm 0.0302$ S.D.), $3.03[(\text{spike/s})/(\text{deg/s})](\pm 1.69$ S.D.), $-16.8[(\text{spike/s})/\text{deg}](\pm 20.7$ S.D.), $58.1[\text{spike/s}](\pm 74.1$ S.D.)となった。細胞毎のデータ組の数の差による平均への影響を考え、評価で残った各細胞毎に1組のデータ(刺激速度は80[deg/s], 全14組)の係数を平均した結果は、 $0.0697[(\text{spike/s})/(\text{deg/s}^2)](\pm 0.0338$ S.D.), $2.64[(\text{spike/s})/(\text{deg/s})](\pm 1.16$ S.D.), $-12.3[(\text{spike/s})/\text{deg}](\pm 9.67$ S.D.), $62.4[\text{spike/s}](\pm 42.8$ S.D.)であった。加速度・速度・位置係数とも分散は比較的小さく、対象となったP-cellの多くはOFR中似たような活動パターンを示すことが判る。バイアス f_{bias} は4.6.2に述べた理由により、負になっているものもいくつかある。

ここで、「各P-cell」と「各視覚刺激速度」を、算出した係数の分類基準として取

り上げ, Fig.5.9の様に分類する. 図で黒点が算出された係数を示す. 菱形の中心線がその分類に属する係数の平均で, 菱形の幅(すなわち各分類に割り当てられた横軸の幅)はその分類に属するデータの数に比例し, 高さは平均値の信頼区間を表わす. それぞれの名義尺度での分類と各係数の間で線形回帰を行うと, Table 5.1に示すように, 各P-cellでの分類の方がM, B, K, f_{bias} , δ いずれの係数に対しても大きな決定係数が得られた. この結果は, 各P-cellで分類してそれぞれのP-cellごとにまとめたデータに対して1つの線形モデル(式(5-1))を使うほうが, 刺激速度で分類してそれぞれの刺激速度でまとめたデータに対して1つの線形モデルを使うよりも, データの説明能力が高いことを表している.

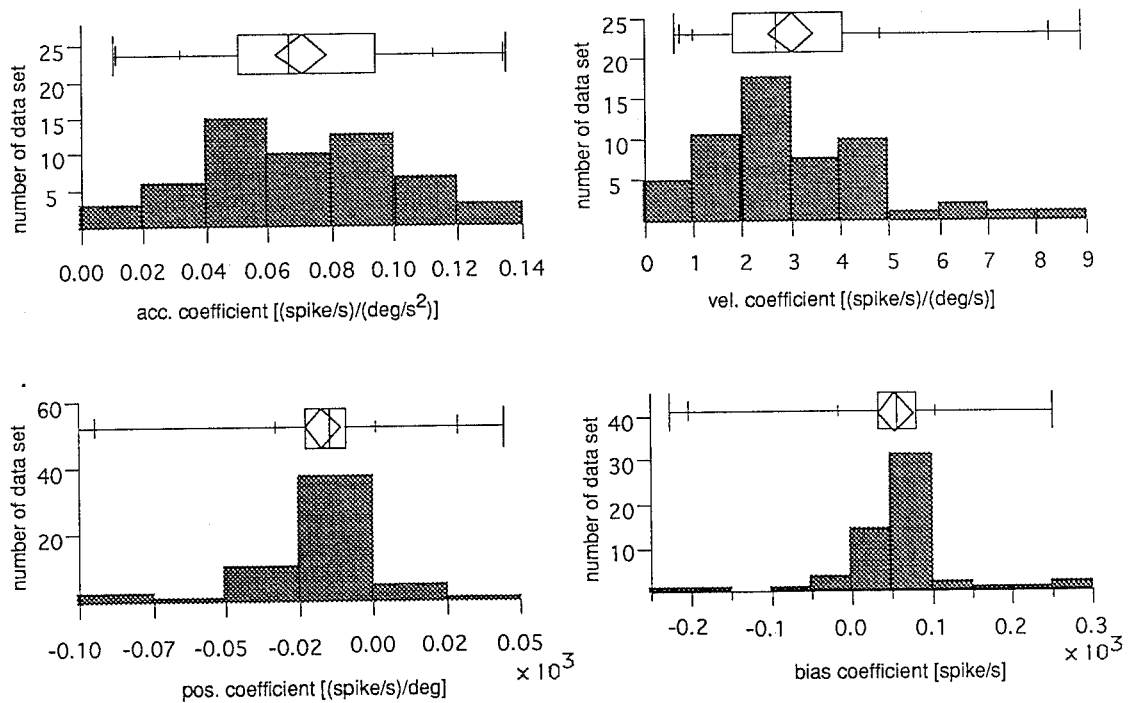


Fig. 5.8 Histograms and and quantile box plots of estimated coefficients

Table 5.1 Coefficient of determinations obtained by fitting between estimated coefficients and nominal categorization by P-cell and stimulus velocity.

	coefficient of determination by fitting categorized data	
	each P-cell	each stimulus speed
M	0.857	0.031
B	0.762	0.299
K	0.476	0.109
f_{bias}	0.472	0.013
δ	0.867	0.021

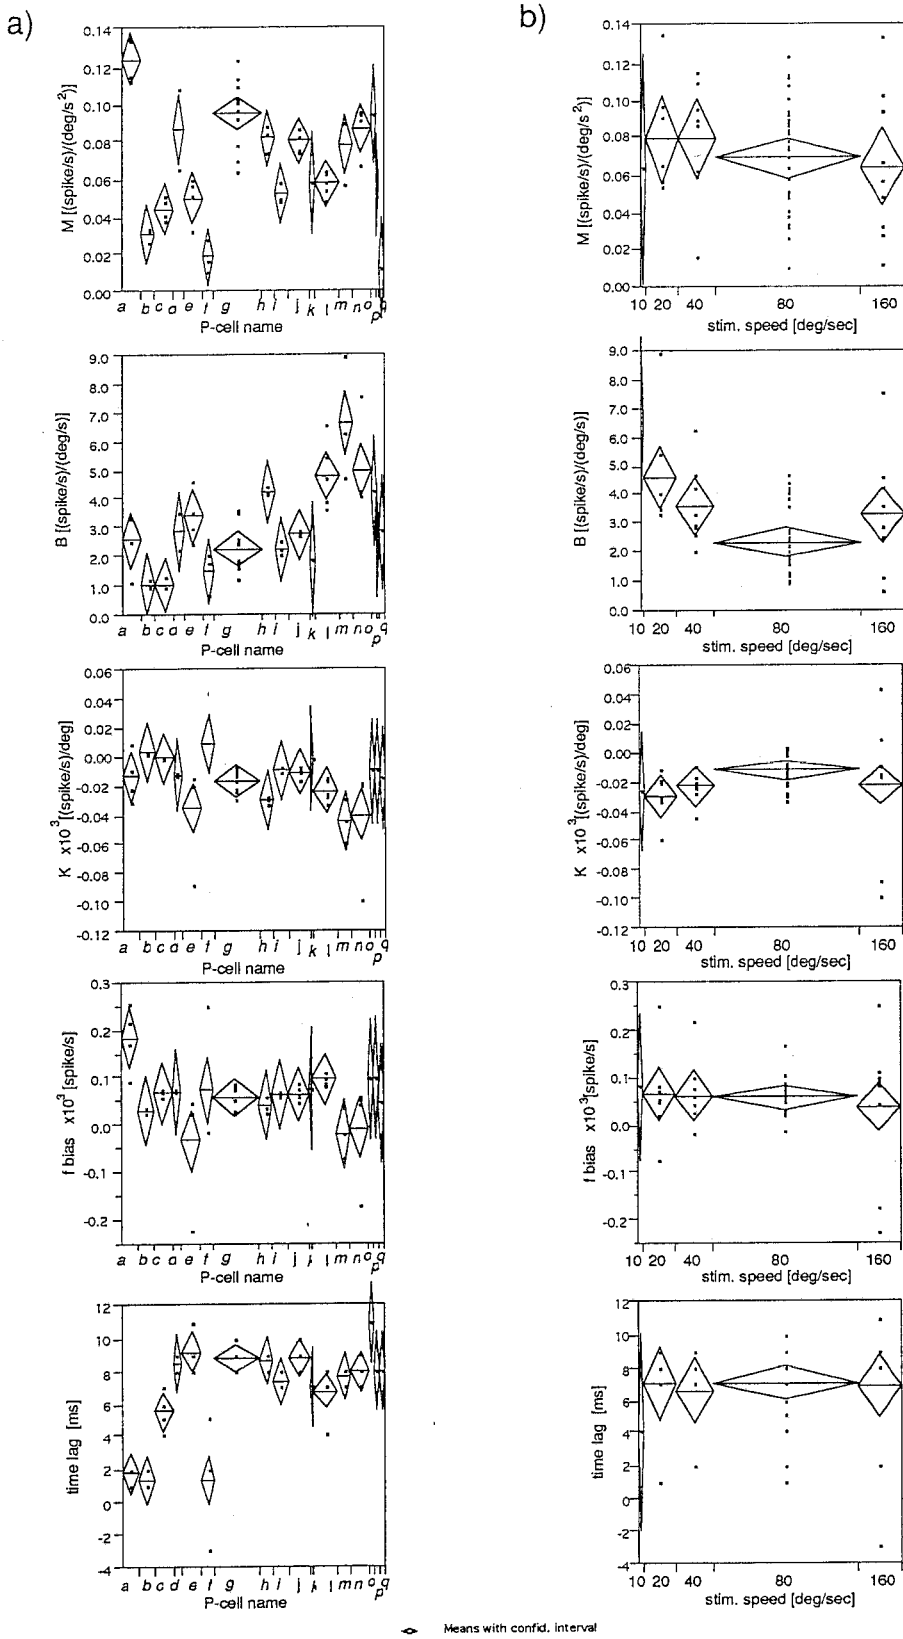


Fig. 5.9 Nominal categorization of estimated coefficients and estimated time lag.
 a) by P-cell b) by stimulus velocity.

(3) 係数の信頼性

さて、潜時差の推定値の信頼性が悪いと考えられるものについては5.4.2(1)で選択の基準を与え取捨選択を行ったが、推定された加速度・速度・位置の係数にはどの程度の誤差が考えられるのだろうか。本解析では、短い時間のデータを使って（約300 ms）で係数の推定を行っているため、ある程度のモデル化（すなわちフィッティング）に成功しても、入力信号間（位置、速度、加速度）の相関が高い場合には、係数の推定精度が悪い可能性がある。付録5-Bで述べるように、この係数の信頼性は、信頼区間を求めることによって判断ができる。Fig.5.10に加速度・速度・位置の係数に対する各推定での95%信頼区間の分散をヒストグラムで示す。

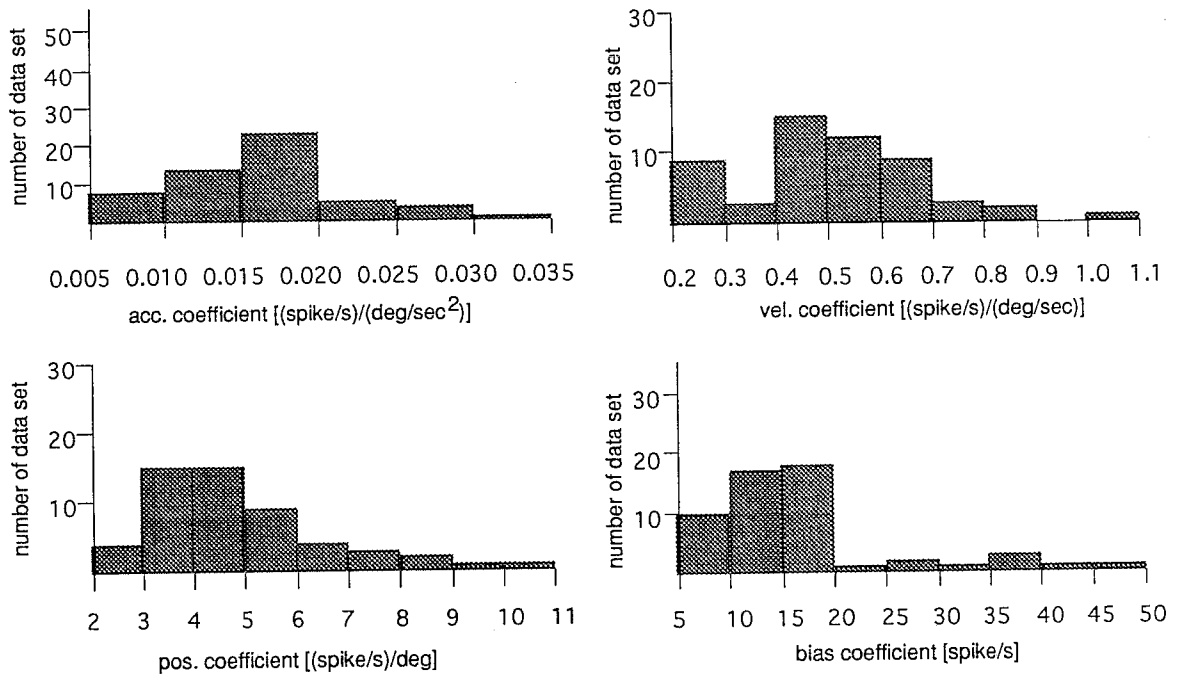


Fig. 5.10 Distribution of 95% confidence intervals of each estimated coefficient.

各係数 (M, B, K, f_{bias}) の信頼区間の平均値は、 $0.016[(\text{spike/s})/(\text{deg/s}^2)](\pm 0.00551 \text{ S.D.})$, $0.574[(\text{spike/s})/(\text{deg/s})](\pm 0.338 \text{ S.D.})$, $7.88[(\text{spike/s})/\text{deg}](\pm 14.7 \text{ S.D.})$, $29.3[(\text{spike/s})](\pm 67.3 \text{ S.D.})$ であった。これらの数値を、各条件別に推定された各係数の分散 (Fig.5.8) と比較すると、各推定係数の信頼区間は分散の数分の一程度に収まっている。そのため、推定係数の信頼性は、推定係数の平均値に対してさほど影響を与えるほど悪くはないと判断できる。

5.4.2 プルキンエ細胞別のデータによる解析

さて、以上の解析では各条件でのデータに対して個々に解析を行っているため、各P-cell、各刺激速度のデータのまわりで線形解析を行ったことになる。ここでは、前記の「刺激速度別分けたデータセットよりも各P-cell別に分けたデータセットに対して線形モデルを適用する方がデータの説明能力が高い」という結果を踏まえ、いくつかの違う条件のもとで取られた各P-cell別のデータセットを線形モデルでどの程度モデル化が可能かを調べる。すなわち、各々のP-cellで観察された、いくつかの異なる刺激速度や異なる刺激呈示時間の場合のデータを全て用いて、最小二乗法により1組の係数を求め、発火頻度を再構成する。またこの解析では、いくつかの条件の下で取られたデータを合わせるため、信号がrichになり、係数やタイムラグの推定の信頼性を上げることができる。Fig.5.11は、6種類の刺激速度（5.2に述べた最適方向への5種類の刺激速度と、1種類の逆方向への刺激速度）、6種類の刺激時間のデータから1組の係数を求めた場合のデータ例である。図の上から、視覚刺激移動速度、P-cell発火頻度、眼球加速度、速度、位置を示す。P-cell発火頻度のグラフで、黒点が観測データで、実線が運動より再構成した発火頻度であり、良く一致している。この場合の決定係数（式(4-5)）は0.78であった。

5.4.1で調べた25個の細胞のうち、4つ以上の異なった条件で取られたデータを持つ11個の細胞のデータをここでの解析の対象とした。調べた11個のP-cellのデータ組において決定係数が0.7以上となったものが10組あり、潜期差推定の信頼性の基準（5.4.1(1)に記述）をクリアしたものはその中で7組あった。その7組のデータによって得られた式(5-1)の各係数の平均値は各々、 $0.0818[(\text{spike/s})/(\text{deg/s}^2)] (\pm 0.0303 \text{ S.D.})$ 、 $3.16[(\text{spike/s})/(\text{deg/s})] (\pm 1.54 \text{ S.D.})$ 、 $15.1[(\text{spike/s})/\text{deg}] (\pm 12.8 \text{ S.D.})$ 、 $76.5[\text{spike/s}] (\pm 48.3 \text{ S.D.})$ 、潜時差は $6.86[\text{ms}] (\pm 2.34 \text{ S.D.})$ であった。これらの値は、各条件別に解析をした場合と近い値になっており、各条件別の解析の値は各細胞毎のデータの数の違いによる変動をさほど受けていない。

以上の結果より、追従眼球運動中のVPFL P-cellの発火は、刺激速度によらず、そのP-cellがよく反応する最適方向の運動の加速度・速度・位置に係数を掛けた線形モデルでほぼモデル化できることが示された。




Fig. 5.11 Reconstruction of a single P-cell firing frequency by one parameter set of linear model.

These firing patterns were induced by several stimulus velocity and several stimulus duration. From top to bottom, stimulus velocity, observed P-cell firing frequency (dots) and reconstructed firing frequency (line), eye acceleration, eye velocity, and eye position.

5.5 考察

5.5.1 順モデル表現による解析手法との比較

Robinson¹¹⁸⁾ は saccade (衝動性眼球運動), gaze (注視), smooth pursuit (追跡性眼球運動) で, Keller¹¹⁹⁾ は vergence (輻輳眼球運動) で, Berthier, Barto & Moore¹²⁰⁾ は瞬膜反射で, 神経発火と眼球運動とを因果律を満たす順ダイナミクスモデルを仮定し, 実測データを用いて伝達関数の係数を求めている. しかし, 先に述べたように, 運動は1つの神経細胞のみによって引き起こされるわけではなく, 多くの神経細胞の発火の影響を受けて起こるものである. Robinsonらが調べた眼球運動細胞では,

運動を引き起こす出力はすべてその部位に収束しており（「最終共通路」と呼ばれる）、かつsaccade, fixationやsmooth pursuitなどの様々な種類の運動に対してその部位の各ニューロンの発火の仕方に差が少ない（すなわちニューロン間の発火の相関が高い）ため、順モデル表現によって運動との関係を調べることは意味があると考えられるが、いくつかの部位が関与する運動において、特定の部位の一部のニューロンの神経発火から運動を再現することは原理的に不可能である。例えば、眼球運動が最終共通路である眼球運動細胞の発火 f_m によって駆動され、P-cell発火 f_i と他の部位の発火 $f_{r,k}$ の加重和により運動細胞の発火が発現するとして、式(5-3)のようなモデルを考える。

$$M_m \ddot{\theta}(t) + B_m \dot{\theta}(t) + K_m \theta(t) = f_m(t - \delta_m) = \sum_i w_i f_i(t - \delta_i) + \sum_k r_k f_{r,k}(t - \delta_{r,k}) \quad (5-3)$$

ここで、 M_m, B_m, K_m は、運動細胞の発火に対する加速度、速度、位置の係数である。この式より、各信号が十分richであれば運動のデータから1つのP-cellの発火は再構成可能であるが、一部の細胞の発火だけからは運動は再現できないことは容易にわかる。本報告の結果も逆モデル表現を用いているため、位置の係数が負になるような推定結果が許されるが、これを順ダイナミクス表現を用いると不安定な系になるため、伝達関数で近似するBerthierら¹²⁰⁾のような方法では、神経発火から運動を良く再現することはできない。この理由により、小脳プルキンエ細胞活動パターンの解析においては、本解析で用いたように逆モデル表現を使用することが必要とされる。

5.5.2 モデル次数の検討

本節では、式(5-1)で用いた逆モデルの次数の妥当性について検討する。従来の研究において、小脳出力が速度あるいは加速度を主にコードしていることは説明されてきたが（付録5-C参照）、システムティックな手法によってどの程度の高次の微分項まで発火パターンの解析あるいはモデル化に必要とされるかが議論されていなかった。また、眼球運動に関する多くのモデル化の研究^{112, 118, 135, 137)}では、位置と速度の項しか考慮されていない。そこで、今回使用した小脳発火パターンの再構成にはどの程度の運動の高次微分項まで必要とされるかを、式(5-1)よりさらに1次上げた3次微分の項（躍度）まで含めたモデル（式(5-4)）を用い、統計的検定手法により検

討した結果を以下に示す.

$$\hat{f}(t-\delta) = J\ddot{\theta}(t) + M\dot{\theta}(t) + B\theta(t) + K\theta(t) + f_{bias} \quad (5-4)$$

ここで, $\hat{f}(t-\delta)$ は, モデルによって再構成される時刻 $t-\delta$ における細胞発火頻度, f_{bias} はバイアス, J, M, B, K は各々躍度係数, 加速度係数, 速度係数, 位置係数である.

まず, 5.4.1で用いた条件別のデータに対して式(5-1)の代わりに式(5-4)でモデル化を行い, さらに, 5.4.1(1)で述べた2つの評価基準(決定係数 >0.7 , および潜時差 δ と決定係数の関係による評価)により55セットのデータを選択した. それらのデータに対して, 式(5-4)右辺の各項の係数が0であるという帰無仮説(null hypothesis)に対しt-検定を行い, 各成分の必要性を検討した. t-検定の際のp値(帰無仮説が成立する確率)の大ききで場合分けしたデータ組の数をTable 5.2に示す. 躍度成分に対してはほとんどのデータ組に対してp値が高く, 帰無仮説を棄却できないケースが多い. 即ち, 躍度項は式(5-4)のモデルに役に立っていないことになり, 躍度まで考慮してモデル化をする必要はほとんどないことが示された. これに対し, 加速度, 速度, 位置の係数の検定では, p値が低いものが大半であり, 発火のモデル化に必要であることが理解できる. さらに, 付録5-Dに示す方法により, モデル撰択の基準であるCp統計量を(A)速度・位置・バイアスを用いたモデル, (B)加速度・速度・位置・バイアスを用いたモデル, (C)躍度・加速度・速度・位置・バイアスを用いたモデル, について求めたが, (B)のモデルがCp統計量が最低になるケースが全データセットの76.6%(72/94)となり, この基準からも(B)のモデルの妥当性が示された.

Table 5.2 Significance of each component in the reconstructed firing frequency.

	Number of data set in each range of pvalue of t-test		
	$p < 0.005$	$0.005 < p < 0.05$	$0.05 < p$
jerk component	5	5	45
acc. component	54	1	0
vel. component	55	0	0
pos. component	47	3	5
bias component	54	0	1

Note: p-values of t-test denote the significance probability of the null hypothesis that a coefficient of each component is zero. If p-value is very small, the model fitting is performed bad when a particular component is dropped.

5.5.3 運動に対する小脳の関与

ここでは、本解析で得られた、「位置の係数が負である」ことがどのようなメカニズムで起こっているのかを考える。この結果の解釈としては、次の可能性が考えられる。

(1)小脳以外の経路によって眼球運動細胞に位置に比例する信号が過大に送られ、小脳は位置に関しては逆に負の成分を出力して調整している。小脳が位置成分をコードするために必要な位置の情報は、別の部位から入力を受ける。

(2)細胞発火と運動との間の非線形の関係により疑似的な相関が出ている。例えば、運動初期（速度が0に近い時）だけ速度比例項が大きく、ある程度動きだすと小さくなると仮定すると、線形解析では速度項が過大に評価されてしまい、位置成分に対して疑似的な相関が出てくる可能性がある。

位置係数が負になる原因を明確にしてゆくためには、顆粒細胞の信号や、P-cell出力先の小脳核あるいは前庭神経核の信号を見ることや、よりrichな入力パターンを用いて解析をすることが必要とされる。生理学的観察によってこれらの信号の関係がはっきりしてきたとき、再考すべき問題である。

さて次に、解析したP-cellの下流にあると考えられる眼球運動細胞における係数の値と比較する。Keller¹¹⁹⁾は、輻輳眼球運動中の眼球運動細胞における神経活動と眼球運動との関係を2次のモデルを使って調べている。そこに示されている平均時定数を使って係数の比を計算すると（加速度係数/速度係数）比は0.015、（位置係数/速度係数）比は5.1となる。今回求めた係数平均で得られたそれらの比は*、それぞれ0.0234, -5.55（各細胞につき1組のデータ(80[deg/s])の係数比だけを対象とした平均は各々、0.0264, -4.68）であり、（加速度係数/速度係数）比はやや今回の方が大きく、加速度成分の比率が高い。加速度成分は運動の立ち上がりの高い周波数成分を含むため、小脳からの信号が運動細胞に伝達する過程で徐々に減衰し、この差が生ずると解釈できる。これに対して、位置係数/速度係数は符号さえも異なっている。運動細胞は最終出力であるためRobinson, Kellerが示したように安定な伝達関数になっている必要があるが、P-cellでは上で述べたようにその必要性はない。この

*ここで示した解析では、安定な伝達関数を仮定していないので、時定数を求めることができない。そのため、係数平均の比によって比較を行った。よって厳密には、Kellerの結果と単純に比較することはできない。

伝達系に線形のモデルを用いるのが妥当であるならば、この結果はP-cellからの出力だけで運動細胞の入力が構成されているのではないことを示している。いずれにしても、Fig.5.6(b)の小脳プルキンエ細胞発火中の各成分を見てわかるように、運動の立ち上がりでは加速度成分・速度成分が主であるため、少なくとも運動のダイナミックな成分は主にP-cell出力によってドライブされていると言える。

5.5.4 小脳における運動司令生成のための内部モデル

以上の生理学データの解析・考察によって、小脳が運動司令の生成に直接線形的に関与している例を示した。次に、小脳でどのような情報変換を行っているかを考える。小脳への入力であるDLPN¹¹⁶⁾やVPFL苔状線維の信号を観察した結果を考慮すると、VPFL P-cellの出力信号とは明らかに異なり、小脳では何らかの信号変換が行われていると考えられる。この変換を単なるフィードバック制御器としてみれるであろうか。生体系の情報処理過程においては伝達に電気回路とは比較にならないほどの遅れが存在するにもかかわらず、眼球や手足はかなり速い運動を正確に行うことができる。ここで調べた眼球運動においても、視覚刺激が入ってから実際に目が動きだすまでには、50-60[ms]程度の遅れがみられる。このような遅れ（無駄時間）の大きい系では単純なフィードバック制御器を使ったのではゲインを上げることができず鈍い応答しか得られない。ここで解析した追従眼球運動以外にもさらに早い眼球運動に小脳が役立っていることを考慮すれば、単純に誤差にゲインを掛けるだけのフィードバック制御器によって運動司令を生成しているというよりは、「観測した視覚誤差や上位中枢からの司令に応じて、制御対象の内部モデルを利用して、思いどおりに動かすための運動司令が小脳によって生成されている」と解釈するのが適切であるように思われる。このことを生理学的により明確にしていくには、本章で扱ったような視覚誤差に対して反射的に反応する運動だけでなく、随意的な運動における神経発火の解析なども行う必要がある。

5.6 まとめ

本章では、小脳プルキンエ細胞が何を表現しているかを検討するため、サル¹¹⁷⁾の追従眼球運動時の小脳傍片葉プルキンエ細胞の発火パターンを線形逆ダイナミクス表

現を用いて再構成した結果について述べた。推定の結果、(1)発火から運動までの潜時差の最大値は電気刺激によって得られたデータとほぼ等しく、(2) (平均加速度係数/平均速度係数) 比は運動細胞のそれと近く、(3)異なる速度の運動にたいするプルキンエ細胞の発火も1つのモデルで精度よく再構成された。このことは、従来の解剖学・電気生理学的知見とあわせて考えると、追従眼球運動に必要な眼球の逆ダイナミクスの動的要素は、主に小脳傍片葉プルキンエ細胞によって生成されていると考えられる。また、小脳入力信号が出力信号とは大きく異なること¹¹⁶⁾や生体情報処理伝達系に内在する大きな遅れの問題、より随意的な運動への寄与などの事実と今回の解析結果から、「小脳は制御対象である眼球のダイナミクスの内部モデルを使って運動司令を生成している」ということが強く示唆された。

今後とも、第4章で述べたような脳の情報処理系のモデル化、および本章で述べたような生理学的データによるモデルの検討を行ってゆくことにより、より多くの部位を含むような、またより多くの機能を説明するような脳の計算モデルへと発展させ検証していくことが、脳の情報処理メカニズムの解明あるいはそのメカニズムの応用において重要であると考えられる。

第6章

運動学習による操作対象物の認識と制御

この章では、操作運動を通して、操作対象物の「内部モデル」と操作に必要な「認識能力」を学習によって同時に獲得してゆく計算モデルを提案する。そして、操作対象が次々と変わっていく状況において、目標とする運動軌道を正確に追従する様な課題を考え、提案するモジュラ構造神経回路による制御器の学習によって、本課題が達成できるようになることを、幾つかのシミュレーションにより確認した結果を示す。

6.1 はじめに

前章までは、学習によって制御対象である眼球や腕のダイナミクスの内部モデルを獲得し、それら内部モデルを利用して制御をおこなう計算モデルの考察、あるいは計算モデルによる生理学的現象の説明を述べた。それらの計算モデルのなかでは、学習される対象である眼球や腕自体のダイナミクスは短期的に見た場合は「時変系ではない」と考えられるため、制御に利用する内部モデルを即応的に再学習させる必要はない。しかし腕などの運動制御では、制御対象が自由空間で単独で動くことよりも、なにか物を持ちたり操作をしたりすることが重要となる。このような「対象物操作」では、操作対象物が替われば、同じ操作をするにも筋への運動司令を大きく変化させなくてはならない。3章で説明した、制御対象の逆モデル（逆キネマティクスモデル、逆ダイナミクスモデル）を学習によって獲得してそれを制御に用いる、直接逆モデル学習^{56,55,60}、順逆モデル学習⁵⁷、フィードバック誤差学習⁹などは、制御対象の物理的特性が学習の間に変化しない（時変系ではない）ことを前提としている。そのため、「対象物操作」のように制御すべき対象がドラスティックに変化するものに対して、即応的な学習ではないこれらの方法をそのまま適用することは出来ない。

さて、物体の操作をする場合、より広く言えば外界と相互作用をする場合、その相互作用によって受けた自分自身の変化の情報（フィードバック情報）が、対象の認識や制御にとって重要となる。このような考察に基づき、3章では、適応フィードバック制御

器により学習型インピーダンス制御を実現し、自分のインピーダンスを自在にコントロールする手法を提案した。しかし、そのスキームでは何らかの上位システムが作用する環境や目的作業に適した目標インピーダンス（式(3-11)で M, B, K の値）を場合に依りて選んで設定する必要がある。

一方、多くの対象をある基準に基づいてカテゴリに分ける方法は、パターン分類などとして研究されているが、それを神経回路モデルで実現する「競合的モジュラネットの学習」が Jacobs & Jordan^{121,122}, Nowlan, Hinton^{123,124}らにより提案された。

本章では、そのモジュラ構造を持つ神経回路モデルと、外界とのインタラクションの結果を学習に反映する能力を持つフィードバック誤差学習法を利用した、対象物操作の学習スキームを提案をする。このスキームでは、複数のセンサ情報（視覚と運動情報）を利用して、対象物の「認識」と「操作」を運動学習によって同時に実現する。次節ではまず、対象物操作の認識の問題について考察する。そして6.3節で、モジュラ構造神経回路モデルによる対象物操作の学習メカニズムを説明し、6.4節にその学習を「一定時間ごとに入れ替わる操作対象を目標軌道に添って動かすタスク」に応用したシミュレーションを示す。その学習のシミュレーションにおいては、操作対象に加えた力と動作結果である位置、速度、加速度を意味する「体性感覚情報」と呼ぶ信号セットと、単純化した網膜パターンである「視覚情報」とよぶ信号セットを、操作対象識別のための情報に利用する。さらに6.5節で、多数の操作対象物を限られた数の内部モデルで表現することを検討し、そのシミュレーション結果を示す。

6.2 操作対象物の認識

従来、物体の「認識」の問題に対するアプローチでは、対象物を抽象的概念(abstract)とむすびつけるために、汎用性があり合理的であると考えられる表現で記述されたテンプレート（内部モデル）を作成し、入力とテンプレートとのマッチングを取ることが行われてきた^{125,126}。しかし、このようなアプローチにおいては、その認識結果が何に利用できるのかという意識が希薄であり、何に対して「汎用」であるのかがクリアではない。それは、その「表現」が単にマッチングの為のものであるからではないだろうか。そこでここでは、合目的な運動学習の中での操作対象物の認識、という問題について考える。物を動かすことが基本である操作運動では、操作対象物が入れ替われば、同じ目的の操作運動をする場合でも、制御司令のパターンを変化させなくてはならない。例えば、水の沢山入ったコップと少ししか入っていないコップでは、それを口に運ぶとき

のコップを握る力や、腕への力の入れ方が異なるであろうし、誤った予想で動かそうとした場合は水をこぼしてしまうことがあるだろう。物体をスムーズに目的どおり操作するためには、どのような物に対して運動を働きかけるのか、あるいは働き掛けているのかを認識する必要があるとも言えよう。さらに、操作を行うための物体の認識は、目的にそって操作（制御）するためであり、操作と無関係な情報を抽出しても意味がない。それらは相互的関係を持っており、認識がうまく行かなければ、操作もうまく出来ないであろうし、認識がうまく出来ても操作がうまく出来なければ対象物操作が成功したことにはならない。すなわち、対象物操作の学習においては、操作に有効な「認識」と「制御」の能力を獲得することが必要となる。これらのことから、対象物操作における「操作能力」および「認識能力」は操作を通じて学習すべきであろうと考えられる。

6.3 モジュラ構造を持つ神経回路モデルによる対象物操作の学習

上記のような考察に基づき、対象物操作を実現する1つの学習法として、「操作」と「認識」を同時に獲得する、Fig.6.1に示すようなモジュラ構造を持つ神経回路モデル^{122,123)}による学習制御スキームを提案する。

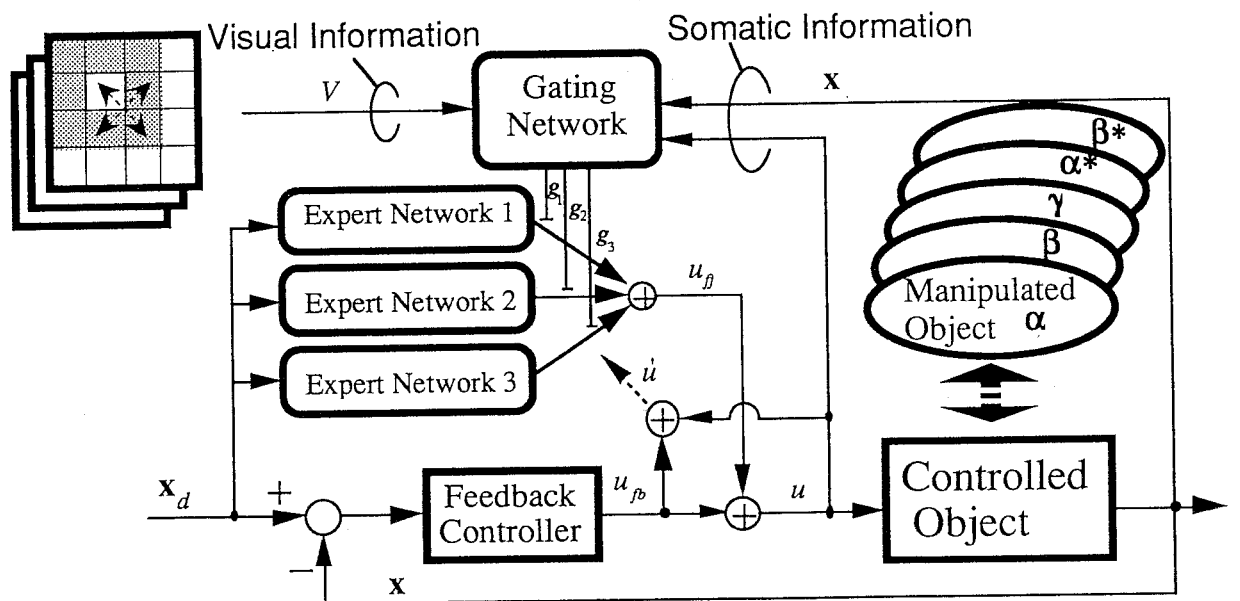


Fig. 6.1 Block diagram of the learning scheme for object manipulation using modular architecture

図から判るように、目標軌道と実現された軌道の誤差は一般的なフィードバック制御器により修正される。制御対象は複数の操作対象と相互作用をするため、固定ゲイン式のフィードフォワード制御ではよい制御性を得ることはできない。操作対象を認識することを学習するGating Networkには、例えば図に示すように、対象物の視覚的パターンに相当する信号や制御対象への入力と出力信号（視覚情報と体性感覚情報と呼ぶ。後ろの文中において式で定義する。）など、操作対象が何であるかを判断する情報が入力され、Expert Networkには目標軌道が入力される。 n 個ある内の i 番目のExpert Network（以下ExptNetと呼ぶ）に対するGating Network（以下GateNetと呼ぶ）の出力を g_i とおき、

$$g_i = \frac{e^{s_i}}{\sum_{j=1}^n e^{s_j}} \quad (6-1)$$

と表す。ここで、 s_i はGateNetへの入力信号で表される内部変数である。また、個々のExptNetの出力 u_i を融合したフィードフォワード制御器の出力 u_{ff} を、次の式で表されるように構成する。

$$u_{ff} = \sum_{i=1}^n g_i u_i \quad (6-2)$$

そして、学習のための評価関数を次式のように設定する。

$$\ln L = \ln \sum_{i=1}^n g_i e^{-\|u' - u_i\|^2 / 2\sigma_i^2} \quad (6-3)$$

ここで、 u' は運動指令（制御対象への入力）の目標値を、 σ_i は i 番目のExptNetに対する正の係数を表す。操作対象の特性が未知の時、目標軌道から u' の正確な値を算出することはできないため、Fig.61に示すように、フィードバック誤差と以前入力した値を使って次式の様に疑似的な目標値 u' を生成し使用する。

$$u' = u + u_{fb} \quad (6-4)$$

学習は、評価関数(6-3)に対する各シナプス荷重についての偏微分を利用して、関数 $\ln L$ を最大化するように全てのネットワークのシナプス荷重（可変パラメータ）を次式にしたがって調整する。

$$\left. \begin{aligned} \frac{dw_{\text{gate}}}{dt} &= \eta_{\text{gate}} \sum_{i=1}^n \frac{\partial s_i}{\partial w_{\text{gate}}} (g(i|X, u') - g_i) \\ \frac{dw_{\text{expert } i}}{dt} &= \eta_{\text{expert } i} \frac{\partial u_i}{\partial w_{\text{expert } i}} g(i|X, u') \frac{(u' - u_i)}{\sigma_i^2} \end{aligned} \right\} \quad (6-5)$$

ここで,

$$g(i|X, u') = \frac{g_i e^{-\|u' - u_i\|^2 / 2\sigma_i^2}}{\sum_{j=1}^n g_j e^{-\|u' - u_j\|^2 / 2\sigma_j^2}} \quad (6-6)$$

であり, η_{gate} と $\eta_{\text{expert } i}$ は各々 GateNet と ExptNet 内のシナプス荷重の学習速度係数, X は GateNet への入力信号ベクトルを表す. このスキームの直感的解釈としては, GateNet が「どの ExptNet がその時点での操作対象の制御にふさわしいかを判断する」ように, ExptNet が「個々の物体にあったフィードフォワード制御をする」ように学習をおこなうものである, と言えよう.

6.4 操作対象物数が Expert Network 数と等しい場合の 学習のシミュレーション

ここではまず, シミュレーションに用いた制御対象を説明する. 制御対象と操作対象は Fig. 6.2 の様に構成している. 図で, M, B, K は制御対象と操作対象を合わせて考えたときの重量, 拘束面に対する粘性および弾性を表し, これらの値は, 操作対象物の変化と共に一定時間 (epoch と呼ぶ. 以下のシミュレーションでは 1[s] に設定した) ごとに変化する. 以下の文中では, 便宜上 M, B, K を「操作対象の特性」として表現する. この状況において, 制御対象 (+ 操作対象) を目標軌道 (時間的に変化する目標位置) に追従させることを, ここでのタスクとする.

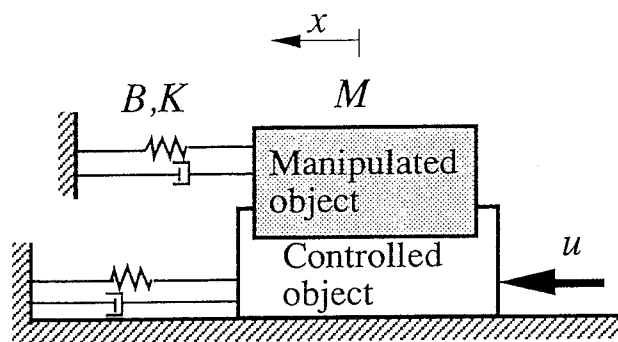


Fig. 6.2 Schematic expression of the controlled object and manipulated object.

Fig. 6.3 は(a)それぞれのepoch (1[s])で乗せられている操作対象がどれなのかを示し、(b)はフィードフォワード運動司令 u_f とフィードバックの運動司令 u_b の学習前の状態を示す。それぞれの操作対象 α, β, γ をのせたときの M, B, K の値はTable 6.1に示す。また、目標軌道は加速度が連続でランダムになるようOU過程⁷⁾を用いている。学習前には、フィードバック制御器だけで制御が行われているため、Fig.6.3(c)に示すように目標軌道と実現軌道に常に差が生じている。特に、この例のように制御対象がドラスティックに変化する場合は、固定ゲイン式のフィードバック制御器では一定の追従性を得ることが困難である。




Fig. 6.3 Temporal patterns of (a) selected object, (b) feedback and feedforward motor command, (c) desired and actual trajectories before learning.

Table 6.1 Object characteristics

Obj. \	M kg	B N/(m/sec)	K N/m
α	1.0	2.0	8.0
β	5.0	7.0	4.0
γ	8.0	3.0	1.0

6.4.1 体性感覚情報を利用した対象物操作の学習

さて、上記の軌道追跡の問題に6.3節で説明した学習スキームを応用する．ここで示すシミュレーションではGateNetの入力として、式(6-7)で示すように、4時点分(2[ms]ごと)の、制御対象に入力した力 u と制御対象の位置、速度、加速度を表すベクトル x を用いた．

$$s(t) = \psi_1(\mathbf{x}(t), \mathbf{x}(t-1), \mathbf{x}(t-2), \mathbf{x}(t-3), u(t), u(t-1), u(t-2), u(t-3)) \quad (6-7)$$

ここで s は式(6-1)中のGateNetの内部変数であり、 \mathbf{x} と u をあわせて体性感覚情報と呼ぶ．ExptNetsには、目標軌道ベクトル \mathbf{x}_d を与え、学習中に変化する操作対象の特性 M, B, K は、学習前と同じTable 6.1に示す値に設定した．GateNetには3層ネットワーク（入力16、中間層30、出力3、中間層のみシグモイド関数）を用い、各ExptNetには、制御対象が線形システムのため、線形ネットワーク（入力3出力1）を使用した．学習係数は各々 $\sigma_i = 0.8, \eta_{\text{gate}} = 1.0 \times 10^{-3}, \eta_{\text{expert } i} = 1.0 \times 10^{-5}$ とした．ただし、 $\sigma_i, \eta_{\text{expert } i}$ は3つのExptNetとも共通である．

Fig.6.4に学習中の u_{fb} 、 u_f の2乗移動平均の様子を示す．学習の進行と共に、 u_f は大きな値を出力するようになっていく．フィードバック制御器の出力 u_{fb} は運動司令の誤差すなわちモジュラネットワークが前向きに制御できていない度合いを示しており、学習が進むにつれ、 u_{fb} は減少している．




Fig. 6.4 The moving average of the squared motor commands (i.e., feedback controller output and modular network output) during learning using somatic information.

Fig.6.5には、学習中の各ExptNetのシナプス荷重の変化の様子を示す。各ExptNetでは別のシナプス荷重のセットが学習されている。このとき、各ExptNetへは各々の制御対象を個別に教えているわけではない。GateNetが各々のExptNetの出力とフィードバック信号によって作られた疑似教師 u との近さを評価し、各々のExptNetに誤差が振り分けられる。どのExptNetがどの制御対象のダイナミクスを学習するかはExptNetのシナプス荷重の初期値や σ, η の値、学習に使用するデータ及び各ネットワークのサイズなどに依存する。ExptNetの間に関数近似能力の差がある場合は、ExptNetの間で競合が起こり、適切なExptNetの選択が行われる¹²¹⁾。また、GateNetも、式(6-3)で設定された評価関数を最大化するように式(6-5)に従って学習が進行するため、正しいExptNetの選択をする能力が上がってゆく。Fig.6.7の1列目の各ExptNetに獲得した「各入力に対するシナプス荷重の値」と、同表2列目に示す各操作対象の M, B, K の値を比較すると、各ExptNetは学習中に用いたいずれかの操作対象の逆ダイナミクスを獲得していることが判る。ここで示した学習の結果では、ExptNet No.1が γ の、ExptNet No.2が β の、ExptNet No.3が α の逆ダイナミクスを獲得している。

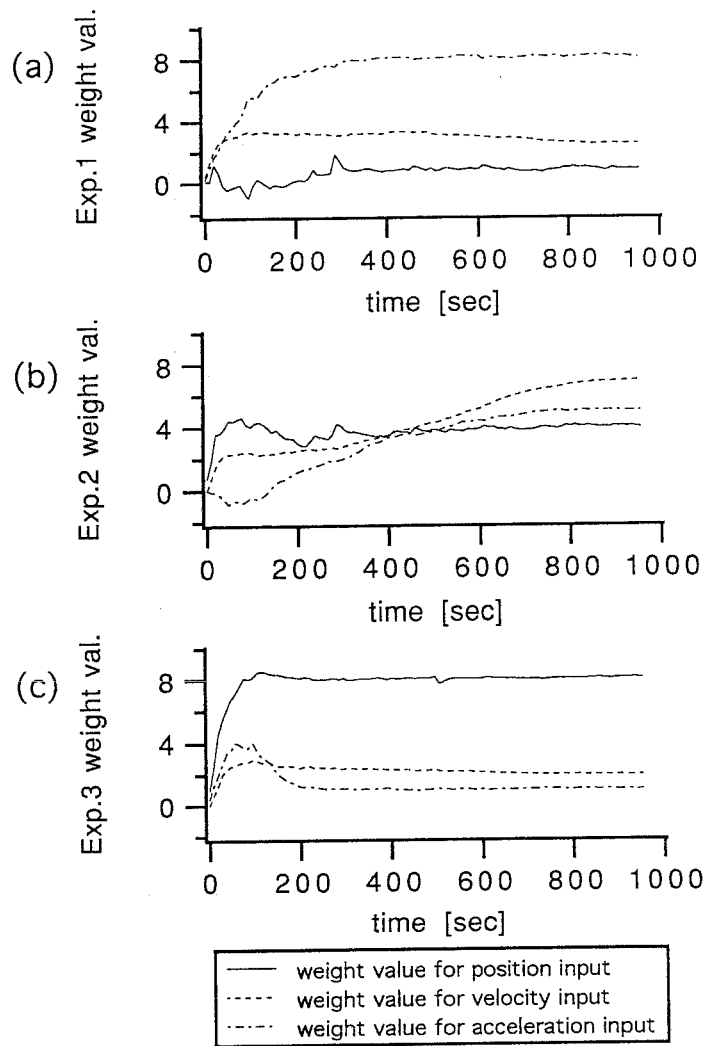


Fig. 6.5 The time courses of expert network synaptic weights during the learning in which somatic information was used as the gating network input.

次に、Fig.6.6に学習後のテスト時の、(a)変化する操作対象、(b)GateNetの各出力 g_i 、(c)フィードバック制御器の出力 u_p とモジュラネットの最終出力 u_{ff} 、および(d)制御対象の位置の目標値と実現値、の様子を示す。どのExptNetが現在の操作対象に対して適合するかを判断するGateNetの出力は、多くの時点で選択されている対象に対応する逆ダイナミクスを持つExptNetを選んでおり、制御対象に加えた u と出力軌道 x によってどの操作対象かを判断する機能が獲得されていることを示している。しかしながら、正しくGateNet出力が得られていない区間も部分的に見られる。例えば、1, 4 [s]付近、16-18 [s]付近では正しいGateNet出力が得られていない。これはGateNetの学習が十分行われていないために発生したと考えられ、神経回路モデル自体の学習やサイズの工夫をすることで

ある程度改善できると考える。ただし、Fig.6.6(c)および(d)からも判るように、適切な ExptNetを選ぶようなGateNet出力が正確に得られていない部分においても、学習の目的である目標軌道への追従はほぼ達成され、その結果フィードバック制御器はそれほど大きな出力をしていない。




Fig. 6.6 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands (i.e., feedback controller output and modular network output), (d) desired and actual trajectories after the learning using somatic information.

さて次に、学習後のGateNetによる操作対象の認識率を示す。学習後GateNetの各ExptNetへの出力を、各操作対象を扱っている時間に分けて平均化して比較したものを、対象の物理特性（2列目）、各ExptNetが獲得したシナプス荷重（1行目）と共にFig.6.7にまとめる。図の各カラムの塗りつぶした部分の高さが認識率を表す。例えば、対象 α の列とNo.3の行の交差するカラムはほとんど塗りつぶされているが、これは α が与えられている間はGateNetのExptNet No.3への出力 g_3 がほとんど1であったことを示している。図より、 α 、 γ へのGateNetへの出力は比較的綺麗に分れ高い認識率を示しているが、 β に対しては認識率が低いことが判る。

	Object physical characteristics <i>M B K</i>	visual cue	Expert Net. Weight values for each input, $\ddot{x}_d \dot{x}_d x_d$, after learning								
			No.1			No.2			No.3		
			\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d
			8.1	2.5	0.87	5.0	6.9	4.0	0.97	1.9	8.0
α	1.0 2.0 8.0	none									
β	5.0 7.0 4.0	none									
γ	8.0 3.0 1.0	none									

Fig. 6.7 Gating network outputs v.s. objects using somatic information. The second column shows the physical characteristics of each object, and the first row shows the acquired parameter values for the inputs to each expert network. The gray bar height denotes each averaged gating network output for each expert network while each object was selected during the test phase after learning.

6.4.2 視覚情報を利用した対象物操作の学習

ここでは、体性感覚情報の代わりに視覚情報を利用して、操作対象物の制御に適した ExptNet を選択させるシミュレーションを示す。このとき、式(6-1)中の GateNet の内部変数 s は、

$$s(t) = \psi_2(V(t)) \tag{6-8}$$

と表せる。 V は視覚情報であり、このシミュレーションでは、Fig.6.1中に示すような 4×4 の格子マス上に、個々の操作対象に固有のパターン (Fig.6.8参照) を、その対象を与えている間ランダムな位置 (4つの取りうる位置のいずれか) に呈示する。各操作対象はFig.6.8に示すように、 3×3 の大きさで表され、1つだけ特定のマスがかけたパターンを持つ。この 4×4 の視覚情報は、白いマスを0黒いマスを1として、Fig6.1に示すように GateNet への入力とする。そして、視覚パターンに対応したFig.6.8に示す特性 M, B, K を持つ操作対象に対して、6.4節の始めに説明した軌道制御を行う。




Obj. \ Visual cue	Visual cue	M kg	B N/(m/sec)	K N/m
α		1.0	2.0	8.0
α^*		1.0	2.0	8.0
γ		8.0	3.0	1.0

Fig. 6.8 Visual cues and object characteristics in the learning using visual information.

GateNet, ExptNetとも6.4.1と同じものを使用し, 学習係数は各々 $\sigma_i = 0.7$, $\eta_{\text{gate}} = 1.0 \times 10^{-3}$, $\eta_{\text{expert } i} = 1.0 \times 10^{-5}$ と設定した. ($\sigma_i, \eta_{\text{expert } i}$ は各ExptNetで共通)

学習中の u_{fb} , u_{ff} の2乗の移動平均の様子と各ExptNetのシナプス荷重の変化の様子をFig.6.9に示す. このシミュレーションで与えた視覚情報は比較的単純であるため, 体性感覚情報をGateNetの入力として用いた場合よりも速く学習誤差が減少している. また視覚パターンは異なるが, 物理パラメータは同じである制御対象 α, α^* の逆ダイナミクスは, ExptNet No.2のみに獲得されている. Fig.6.10に学習後のテスト時の応答の様子を示す. GateNetの出力 g_i からわかるように, 体性感覚情報をゲートの入力にした6.4.1の場合に比べ安定にExptNetが選択されている. また, ExptNet No.1に対するGateNetの出力 g_1 はほとんど零であり, このExptNetは学習の結果使用されなくなったことがわかる. どのExptNetがどの対象に選択・使用されているかを割合で示すFig.6.11から, 体性感覚情報を利用した場合に比べ操作対象の認識率が非常に高く, また同じ物理特性を持つ α, α^* に対しては, ExptNet No.2が共用されていることが判る. すなわち, 異なる視覚パターンを持つ操作対象に対しては, 別々に内部モデル(この例では逆ダイナミクスモデル)が獲得されるのではなく, 目的とする運動を遂行するための運動司令が同じであれば, それらは1つのモデルによって表現され, 複数の対象に対しその1つのモデルを選択・使用するという, 一種の分類能力をこの学習が持っていることを, この結果から理解できる.




Fig. 6.9 The moving average of the squared motor commands (i.e., feedback controller output and modular network output), and the time courses of expert network synaptic weights during the learning using visual information.




Fig. 6.10 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands, (d) desired and actual trajectories after the learning using visual information.




	Object physical characteristics M B K	visual cue	Expert Net. Weight values for each input, \ddot{x}_d \dot{x}_d x_d , after learning								
			No.1			No.2			No.3		
			\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d
			4.3	3.0	-0.34	1.2	2.0	8.0	8.0	3.0	0.99
α	1.0 2.0 8.0										
α^*	1.0 2.0 8.0										
γ	8.0 3.0 1.0										

Fig. 6.11 Gating network outputs v.s. objects using visual information.
(Same notation with Fig. 6.7)

6.4.3 視覚・体性感覚情報を利用した対象物操作の学習

ここでは、視覚と体性感覚の両方の情報を利用して対象物操作の学習をおこなう例について示す。両情報をGateNetの入力とするので式(6-1)の s は次式で表される。

$$s(t) = \psi_3(\mathbf{x}(t), \dots, \mathbf{x}(t-3), u(t), \dots, u(t-3), V(t)) \quad (6-9)$$

このシミュレーションでは、Fig. 6.13に示す様に操作対象 α と β^* は同じVisual cueを用い、物理パラメータは3つとも異なる (Fig.6.13 2列目に示す値) という条件のもとで学習を行った。2つの物体に対する視覚情報は同じであるから、視覚情報のみで対象を識別しExptNetを選ぶ事は出来ない。また、体性感覚のみでは、6.4.1に示したシミュレーション結果からもわかるように、正確な識別が困難である。視覚情報を補助手段としてExptNetの選択を行うことにより、体性感覚のみを用いた場合より正確なGateNetの出力が得られ、目標軌道の追跡が正確に行えることが望ましい。

学習に用いたGateNetは、3層ネットワーク (入力32, 中間層50, 出力3, 中間層のみシグモイド関数) でExptNetは上のシミュレーションで使用した物と同じ線形ネットである。各々の学習係数は、 $\sigma_i = 1.0, \eta_{\text{gate}} = 1.0 \times 10^{-3}, \eta_{\text{expert } i} = 1.0 \times 10^{-5}$ とした。

Fig.6.12に学習後のテスト時の様子を示す。体性感覚情報だけを利用した6.4.1の場合と比べ、与えられた対象物に対してGateNetがより正しく出力している。Fig.6.13に示すGateNetの出力と操作対象物との対応を見ても、対象物の認識率は体性感覚だけを用いた6.4.1の場合よりも高く、視覚情報と体性感覚情報がうまく融合されて利用されていることが判る。ただし対象物 γ は、Visual cueのみで識別可能であるにもかかわらず、6.4.2で示した視覚情報だけを認識に利用した場合よりも認識率が下がっている。これは、認識のための信号の入力数が増え、神経回路モデルのサイズが大きくなったことによる学習能力の低下によるものと考えられる。

操作対象が何かを判断するためのGateNetへの入力情報は、多種類用意するほうが適切な認識が行われるように思われるが、適切な情報を選択し利用する能力は学習によって獲得しなければならないため、認識能力は学習能力に大きく依存する。この例でも、対象物 γ の認識において、学習が困難である体性感覚情報がかえって障害となり、認識率の低下を引き起こしている。不要な情報が多いほど、学習は困難になることが予想される。与えられた課題において、どのように有効な情報に注意を向け、それを選択的に取り出すことによりロバストな認識を実現するか、を今後検討する必要がある。




Fig. 6.12 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands, (d) desired and actual trajectories after learning using somatic and visual information.

	Object physical characteristics M B K	visual cue	Expert Net. Weight values for each input, \ddot{x}_d \dot{x}_d x_d , after learning								
			No.1			No.2			No.3		
			\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d
			8.1	2.4	0.8	5.1	6.9	4.0	1.0	1.9	8.0
α	1.0 2.0 8.0										
β^*	5.0 7.0 4.0										
γ	8.0 3.0 1.0										

Fig. 6.13 Gating network outputs v.s. objects using somatic and visual information. (Same notation with Fig. 6.7)

6.4.4 未学習の対象物に対する応答

上で提案した学習を未知の対象物の制御に使用した場合、未学習の対象物に対してはどのように応答するのであろうか。ここでは、6.4.1で示した体性感覚情報のみで学習を行ったネットワークを使って、学習に使った対象とは少しづつことなる物理特性 M, B, K を持つ対象 α', β', γ' (個々の特性はFig.6.15 中に記載) で学習後のテストを行った結果をFig.6.14とFig.6.15に示す。(対象物の特性の違いはFig.6.15とFig.6.7の2列目に記載した値を比較参照のこと)

操作対象は学習に用いたものとは少しづつ異なるにも関わらず、GateNetの各出力は、学習時の操作対象と近い特性を持つ対象に対して反応している。すなわちFig.6.15からも判るように、特性が α に近い α' が与えられている時は、高い確率でExptNet No.3 が制御を行っており、他の対象 β', γ' に対しても β, γ のためのExptNetが各々比較的大きな割合で選択されている。ここで示した方法では、式(6-6)で示されるように各ExptNetの出力と教師との距離を評価して学習しているため、各々のExptNetに分担させた学習時の入力に近いデータに対しては、ある程度GateNetがそのExptNetを選択をする事が期待できる。ただし、Fig.6.14の13[s]付近の状況のように、適切なExptNetの出力が行われなかったために、モジュラネットの出力する運動司令 u_{ff} が適切でなくなり、軌道の誤差が生じることもある。学習の汎化能力を高めるために、どのように学習パラメータ σ を設定するかということは今後の検討課題である。




Fig. 6.14 Temporal patterns of (a) selected object, (b) gating network outputs, (c) motor commands, (d) desired and actual trajectories, during an trajectory tracking task with unknown objects using somatic information.

	Object physical characteristics M B K	visual cue	Expert Net. Weight values for each input, \ddot{x}_d \dot{x}_d x_d , after learning								
			No.1			No.2			No.3		
			\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d	\ddot{x}_d	\dot{x}_d	x_d
			8.1	2.5	0.87	5.0	6.9	4.0	0.97	1.9	8.0
α'	2.0 3.0 7.0	none									
β'	4.0 6.0 5.0	none									
γ'	9.0 2.0 2.0	none									

Fig. 6.15 Gating network outputs v.s. objects during an trajectory tracking task with unknown objects using somatic information. (Same notation with Fig. 6.7)

6.5 多数の操作対象のための内部表現の獲得

上で示した学習スキームを見直してみると、最終的な出力の誤差を小さくするように GateNet がその入力空間を部分空間に分割し、ExptNet がその部分空間に対しての適切な出力を出すよう学習が進行する、と解釈できる。そのため、学習時に与えられた操作対象の数が ExptNet の数と一致しているあるいは少ない場合は、各々の ExptNet は各々の操作対象物のほぼ完全な逆モデルを学習で獲得する。そして GateNet は、与えられている操作対象にしたがって正しい ExptNet を選択する様に学習が行われる。

それでは、ExptNet の数が操作対象物の数より少ない場合にはどうなるだろうか。限られた数の内部モデルで多くの対象物をうまく扱うことが、同じ学習で可能であろうか。上記の 1 自由度の線形制御対象を考えた場合、 M, B, K パラメータの 3 次元空間で 4 つの代表点を ExptNet が表現し、かつ、うまく 4 点へのベクトルの合成が出来るのであれば、その 4 点で張られる空間内部の点に対応する対象物を表現することができる。これは、いくつかの対象物の特性を組み合わせ、正確な内部表現を持たない対象物に対しての特性を表現し、それを使って適切な制御を実現することを意味する。本節では 6.4.1 と同様、体性感覚情報のみを GateNet の入力とした場合のみを扱う。すなわち、GateNet の内部変数 s は、

$$s(t) = \psi_1(\mathbf{x}(t), \mathbf{x}(t-1), \mathbf{x}(t-2), \mathbf{x}(t-3), u(t), u(t-1), u(t-2), u(t-3)) \quad (6-10)$$

とする。

6.5.1 学習シミュレーション結果

Table 6.2 にここでの学習に使用した 10 個の操作対象の特性を示す。それらの学習に用いた対象は、Fig. 6.16 に小さい黒点で示すように、各軸 [kg], [N/(m/s)], [N/m] を単位長さとして持つ M, B, K の 3 次元パラメータ空間で正 4 面体の頂点とその 4 つの頂点の内分点にあたる特性を持っている。モジュラ構造ネットワークには、前節と同様線形のネットを ExptNet として使い、3 層ネットワーク（入力 16, 中間層 50, 出力 4, 中間層のみシグモイド関数）を GateNet として用いた。また学習係数は、 $\sigma_i = 1.0, \eta_{\text{gate}} = 1.0 \times 10^{-3}, \eta_{\text{expert } i} = 5.0 \times 10^{-5}$ と設定した。

目標加速度・速度・位置の入力に対する ExptNet のシナプス荷重は M, B, K に対応させることができるため、20000[s] ($\Delta t = 2[\text{ms}], 10^7 \text{ times}$) 学習した後に ExptNets に獲得された M, B, K の値を Fig. 6.16 に大きい黒点でプロットする。原点付近を初期値とした 4 つ

のExptNetのシナプス荷重は、学習に用いた10個の操作対象で表現される正4面体の頂点に近い特性を学習によって獲得しており、ExptNetの出力を適切に合成することにより、4面体内部の空間を表現できる能力を得たことになる。Fig.6.17に学習後のテスト時における、(a)変化する操作対象、(b)フィードバック運動司令 u_{fb} とフィードフォワード運動司令 u_{ff} 、及び(c)制御対象の位置、の様子を示す。学習後には、Fig.6.17(b)で示すように、フィードバック制御器の出力 u_{fb} は、操作対象が変化してもほとんど零の状態を保ち続けている。すなわちこの結果は、操作対象の変化にしたがってExptNetが選択・合成され、状況に応じて適切なフィードフォワード運動指令が出力されていることを示している。

Table 6.2 Sample objects

obj. No.	M [kg]	B [N/(m/sec)]	K [N/m]
0	9	9	9
1	9	2	2
2	2	9	2
3	2	2	9
4	9	5.5	5.5
5	5.5	9	5.5
6	5.5	5.5	9
7	4.33	4.33	4.33
8	7.44	3.55	3.55
9	3.55	7.44	3.55




Fig. 6.16 Sample objects (small spheres) and acquired internal model in ExptNets (big spheres) represented in M, B, K (mass, viscosity, stiffness) parametric 3D-space.




Fig. 6.17 Temporal patterns of (a) the objects, (b) the motor commands, (c) the desired and actual trajectories, after learning

6.6 考察

6.6.1 学習パラメータの設定

上で提案した学習スキームは、収束性や学習パラメータの設定に関して理論的検討はまだ不十分であり、学習を左右する σ, η などの学習パラメータの値は問題に応じて経験的に設定しなくてはならない。特に、上の例題で示した運動司令の学習のように、正確な教師が得られないような場合には、それらの学習パラメータの設定が難しい場合がある。いま、各学習速度係数 η を一定として、教師信号からのずれを評価する σ が相対的に小さいと仮定すると、式(6-5)から判るように、完全に正しくない教師信号（疑似教師信号）によって生ずる不正確な誤差 $u' - u_i$ を大きく評価してExptNetに与えることになり、学習がうまく行われぬおそれがある。また、完全に正しい教師信号が得られる場合でも、 σ を相対的に小さくしすぎると、各ExptNetへの誤差を過大に評価してしまうことから、学習系が不安定になる可能性がある。さらに、 σ は6.4.4で検討した未学習データに対する性能や、6.5で検討した多数の対象を少数の内部モデルで扱う場合などの学習の汎化問題とも関係する。式(6-6)から判るように、 σ はGateNetによって選ばれる各ExptNetの担当するエリアを決めている。よって、 σ が大きいということは、各ExptNet

の担当するエリアを広くとることになり、汎化性能が上がる反面、学習に時間を要したり、正確なExptNetの選択を行わせるための学習が出来なくなったりすることがある。学習を安定に進めるためには η_{ei} と σ とのトレードオフを考慮する必要がある。

また、 σ と η_{ei} でコントロールされるExptNetの学習速度は、 η_g でコントロールするGateNetの学習速度に比べ遅くする必要がある。ExptNetの学習速度が速すぎる場合、1つのExptNetだけが使用され、それが対象物の変化に応じて再学習を繰り返し、個々のExptNetが有効に利用されず、モジュラ構造を生かした学習がうまく行われなことがある。 σ を学習させることも含め、どのようにそれらのパラメータを調整するのがよいかは今後の検討課題である。

6.6.2 適応制御のアプローチとの比較

以上で用いた1自由度軌道制御の例題に対しては、適応制御を利用して線形パラメータを高速に調整して制御するほうが、学習（適応）の為に要する時間も短く、収束性も理論的に示すことができ、パフォーマンス（目標軌道への追従性）もよいであろうと考えられる。しかし、制御対象の構造が未知の場合や制御対象が線形パラメータを使って記述できない場合に対して、従来の適応制御系ではうまく対応できないことが予想される。3章で指摘したように、従来提案されてきた適応制御系では、制御対象の構造を既知であるとして利用し、動作中変化する要素を線形パラメータで表し、そのパラメータを実時間で調整することで制御性を向上させることが一般的であった。そのため、線形パラメータを使って動作中変化する要素を記述できない場合には、制御対象を線形化して考え、制御のためのパラメータ調整を行うことになるが、これを高速に安定に実現することは困難である。それに対し、本章で提案した方法は、ある状態で獲得したパラメータを外界の内部モデルの1つとして何処かのメモリに保存しておいて、次に類似の制御対象が与えられた際には、その保存しておいたパラメータを取り出して利用することにより制御を実現するというような考え方であり、高速なパラメータ調整は必要としない。

さて、生体系における運動制御を考えた場合、果たして適応制御のような高速なパラメータ調整を行うことによって制御対象の変化に対応していると考えられるだろうか？

我々は、物を操作するとき、その対象に関するなんらかの獲得した知識を利用して、どの程度の力を発生して動かせばよいか、すなわちどう運動司令をだせばよいか、などをあらかじめ予測することが多いと考えられる。また操作対象を少し動かした結果得られた感覚のフィードバックにより、自分の予想とは違った別の対象であることが判った

ときは、その別の対象に関する既知の知識を利用して、運動司令パターンを変更していると考えられる。また、未知のダイナミクスを持つもの（例えば新しい運動機具など）で既に獲得した知識が利用できない場合は簡単には思いどおり制御することは出来ない。これらの現象は、人間が制御に利用できる知識として操作対象の内部モデルを持っていることを示唆している。

本章で提案したような、制御対象を認識して、その制御対象の内部モデルを利用して制御を行うことを学習で獲得する方法は、人間の操作運動に似た側面を持ち、複雑な問題にも対処できる可能性を持っていると考える。

6.7 まとめ

本章では、運動学習による操作対象物の認識とその制御について考察し、モジュラ神経回路モデルを用いてそれを実現する計算モデルを提案した。このモデルの基本は、操作対象の内部モデル獲得と、状況を知るための情報を使った適切な内部モデルの選択を、学習によって可能にするというものである。モデルの有効性については1自由度運動のシミュレーションにより検討し、多数の操作対象でも少数の内部モデルによってその制御を可能とすることができることを示した。

ここで示した例題では、ExptNetに学習される内部モデルを明確に示すため、1自由度の線形制御対象を用いたが、提案した手法は非線形性を学習することが出来るネットワーク（例えば3層シグモイドネットワーク）をExptNetとして用いることで、ロボットマニピュレータやプラントなど非線形性を含む対象にもそのまま利用することが出来る。また実際の応用に際しては、各々の制御対象に対しての制御器を予め学習などにより十分な精度で作成した後それらをExptNetとし、GateNetのみを学習させ制御対象の変化に応じて適切な制御器を対応させることで、全体のパフォーマンスの向上や学習の効率化を計ることも可能である。

第7章

結論

本論文は、中枢神経系による運動機能を実現する情報処理の中で、スムーズな運動の実現とその適応・学習のための制御メカニズムに焦点を当て、次の3点の考察を行い結果についてまとめた。

(1) 従来の研究では明らかにされていなかった、内部モデル制御仮説に対立する仮想軌道制御仮説の是非を運動学的実験により検証した。

(2) 運動の学習に重要な役割を果たすと言われる小脳で制御対象である腕や眼球の内部モデルの獲得が行われているかどうかを、従来の運動学・生理学的実験結果の検討および小脳の活動と眼球運動のデータの解析により考察した。

(3) 内部モデルを獲得しそれを制御に利用するいくつかのメカニズムを提案し、その有効性をシミュレーションにより検討した。

以下に、本論文の結論として各章ごとの要点を述べる。

第2章では、随意運動制御に関する仮説である「内部モデルを必要としない仮想軌道制御仮説」の是非を検証するため、人腕の運動中のステイフネスを計測した結果についてまとめた。仮想軌道制御仮説においては、「中枢神経系は制御対象である腕の複雑なダイナミクスを考慮せずに軌道制御を行うことができる」というのが大きなセールスポイントであった。しかし、ダイナミクスを考慮せずに実現軌道を仮想軌道（計画軌道）と似たものにするためには、運動中のステイフネスは高く保たれる必要があった。しかし計測の結果、運動中のステイフネスは静止中と同程度あるいはそれより低くなっていた。このことは、腕を思いどおりの軌道に添って動かすためには、中枢神経系は腕のダイナミクスを考慮して運動司令を生成する必要があること、すなわち内部モデルを使っていることを示唆するものであった。

第3章では、制御対象の内部モデルをどのようなメカニズムで獲得し、それがどのように制御に役に立つのかということ、制御モデルの立場から考察し、「フィードバック誤差学習」を拡張した2つの学習スキーム（「逆モデル学習」および「非線形レギュレータ学習」）を提案した。倒立振り子制御のシミュレーションにより、両提案手法の有効性を確認し、また逆モデル学習をロボットマニピュレータに適用することにより、学習型インピーダンス制御が実現できることを示した。このような内部モデル獲得のメカニズムとその有効性を考察することは、そのメカニズムの生体系での実現の可能性を検討する1つの重要なアプローチであると考えられる。

第4章では、生体系における様々な運動学習原理のモデル化の枠組みを、小脳を中心とした統一的な運動学習スキームとして提案した。そして、従来調べられてきた生理学・解剖学などの知見を基に、3章で説明した内部モデル獲得のメカニズムと生体での運動学習系がどのように対応するのかを、眼球運動系や姿勢制御系を取り上げて考察した。

第5章では、サルの眼球運動時の小脳神経活動のデータを解析することにより、小脳の眼球運動への関与を定量的に明らかにした。また、小脳出力細胞（プルキンエ細胞）の発火頻度が眼球運動の情報（加速度・速度・位置）によって再構成可能であることを示した。これらの解析結果は、小脳が内部モデルを利用して運動司令を出力している可能性が強いことを示唆している。

第6章では、腕や眼球など体の一部の制御ばかりでなく、操作対象物など外界の物に対しても、その内部モデルを学習によって獲得する様なスキームを提案した。この学習スキームでは、操作の際に複数のセンサ情報を用いて物体を認識する能力も学習によって獲得し、認識結果に基づき内部モデルを選択・融合し運動制御に用いるようなメカニズムを有している。この提案手法の有効性は、操作対象が変化するような1自由度の軌道追従制御を例題としてシミュレーションにより確認した。またこの学習スキームは、外界の状況を認識しそれを運動司令に反映させるという対象物操作の基本機能をモデル化したものであり、外界の内部モデル獲得の重要性や、生体運動系における対象物操作学習のメカニズムを考察する上で有用なモデルであると考えられる。

以上述べたように本研究では、生体運動制御系における内部モデル獲得の必要性とそのメカニズム、有効性について多角的に検討し、その結果、(1) 中枢神経系は、制御対象のダイナミクスを考慮しない「仮想軌道制御」を行っているのではなく、獲得した内部モデルを運動司令生成に使っていると考えられること、(2) 眼球や腕などの内部モデル獲得は小脳で行われていると考えられること、がわかった。本研究で行ったアプローチをさらに個々の運動系についても行うことにより、さらに詳細な脳情報処理の理解が進むものと確信する。また、本研究で提案したいくつかの学習制御モデル（3章、6章）は、工学的にも十分有用であると考えられ、多くのモデル化が困難な対象の制御などに役立つことを期待する。

謝辞

本論文をまとめるにあたり、早稲田大学大学院理工学研究科 加藤一郎教授には、丁寧なる御指導と御教示を賜りました。ここに慎んで深謝の意を表します。また、論文をまとめるに際し、早稲田大学大学院理工学研究科 示村悦二郎教授、内山明彦教授、梅津光生教授、三輪敬之教授、高西淳夫助教授には、有益な御討論、御助言を賜りました。特に、高西淳夫助教授には論文作成にあたり御指導を頂きました。ここに記し、深く感謝いたします。

本研究は、著者が(株)ATR視聴覚機構研究所、および(株)ATR人間情報通信研究所に在籍中に行われたものであります。本研究の機会を頂き、また多くの発表の機会を与えて頂きました、(株)ATR視聴覚機構研究所 淀川英司社長(現 工学院大学教授)、同認知機構研究室 中根一成室長(現 (株)NTT ヒューマンインターフェース研究所グループリーダー)、(株)ATR人間情報通信研究所 東倉洋一社長、同第3研究室 川人光男室長に感謝いたします。特に、川人光男室長には、ATR視聴覚機構研究所で本研究を開始したおりから、終始有益な御議論および適切なお指導を賜わり、また新しい研究への興味や意欲を与えて頂きました。あらためて深謝の意を表します。また、本研究の途上において貴重な御討論および御協力を頂いたATR人間情報通信研究所の宇野洋二主任研究員、佐藤雅昭主任研究員、和田安弘主任研究員(現(株)川崎製鉄)、安藤広志研究員、片山正純研究員(現(株)三洋電機)、平山亮研究員、加藤宏明研究員、今水寛研究員、大槻弘幸研究員、小池康晴研究員、鈴木敏研究員、渡辺洋研究員、大須里英子研究員、Eric Vatikiotis-Bateson客員研究員、Edward B. Gamble客員研究員、Frank Pollick客員研究員、Erik McDermott客員研究員に心から感謝いたします。そして、日頃、様々な手助けをいただいている秘書の難波美恵子さんに感謝いたします。加えて、多くのご助言・御協力を頂き、支えていただいた(株)ATR視聴覚機構研究所ならびに(株)ATR人間情報通信研究所の皆様にも心から感謝いたします。

また、共同研究を通して、生理学的知見をたくさん教えていただき、また多くの議論をしていただいた、通産省電子通信総合研究所の山根茂博士、河野憲二博士、設楽宗孝博士、ロボットを動かすノウハウなどを教えていただいた、Prof. Christopher G. Atkeson, Dr. Stefan Schaal (MIT)に改めて感謝の意を表します。

さらに、学会や研究会において多くの先生方、研究者の方に様々なご指導を頂きましたことに厚く御礼申し上げますと共に今後のご活躍を御祈り申し上げます。

なお、著者の出向元である(株)NTT ヒューマンインターフェース研究所 高野睦男所長、同知能ロボット部 酒井高志部長、同柿崎隆夫グループリーダー、岩城敏主任研究員、同境界領域研究所 小暮賢司部長には、多大なる御支援・御助言を頂きました。ATRでの研究を温かく見守っていただきました諸氏にも心から御礼申し上げます。

付録

第2章付録

2-A スティフネスと平衡位置の関係

筋骨格系が加速・減速を伴う運動をしているとき、筋力の差でトルクを発生している状態を、簡単のためFig.2-A.1(a)に示すような1自由度のリンクが2つの筋肉で駆動されている筋骨格モデルで考える。筋骨格系は、この図に示すようにバネとして見なせる筋の力の差によって運動が生ずると考えられるため、通常のモータとは異なり、任意の状態において釣り合い位置（平衡位置）が存在する。筋の通常の使用範囲においては、筋の長さ—張力曲線は単調性を持つため、各筋の主働方向への筋力（トルク）と関節角の関係はFig.2-A.1(b)の実線・点線の組のように表すことが出来る。図で太い矢印は関節角 θ において主働筋と拮抗筋の張力差によって生ずるトルクである。

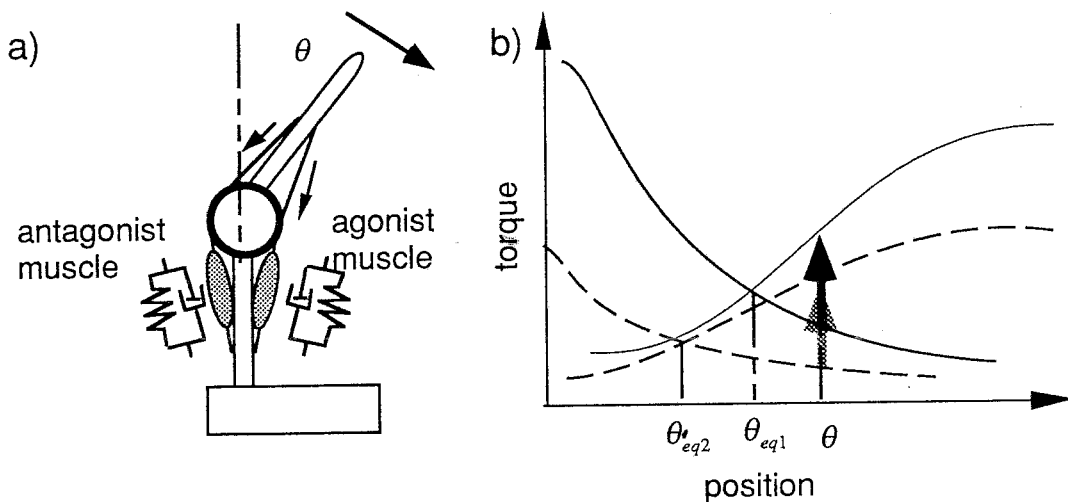


Fig. 2-A.1 a) One degree of freedom muscle-link model. b) Simplified length-tension (torque) curves of agonist and antagonist muscles.

簡単のため、筋の長さ—張力曲線の傾きは一定であるとして、この状態を式で表すと次のようになる。

$$\tau = K(\theta - \theta_{eq}) \quad (2-A-1)$$

ここで、 τ は関節周りのトルク、 K は主動筋と拮抗筋によって発生する合成ステイフネスである。上の式から判るように、Fig.2-A.1(a)のモデルのリンクが、ある位置・速度で、あるトルクを出している瞬間において、リンクの平衡位置と筋のステイフネス（筋の長さ—張力曲線の傾き）は一般に一意には定まらない。例えば、Fig.2-A.1(b)の実線と点線で表される筋肉の状態において、太い矢印で示される駆動トルクは等しいが、平衡位置とステイフネスは異なっている。実線の場合には、両筋の合成ステイフネスは高く、平衡位置 θ_{eq1} は実際の位置 θ の比較的近い所にあり、点線の場合には、合成ステイフネスは低く、平衡位置 θ_{eq2} は θ_{eq1} より遠いところにある。

よって、筋骨格系の実際の位置が平衡位置から大きく離れているかどうかは、筋の長さ—張力曲線の傾が実用域において位置に対してほぼ一定であると考えれば、現在位置での筋の合成ステイフネスを計測すれば調べることが出来ることになる。

2-B Flashの仮定した運動中のステイフネス

Flash¹¹⁾は静止中の手先ステイフネスをデカルト座標系(x-y coordinates)で計測し、デカルト座標から関節座標への変換を行って肩・肘のステイフネスを求めている。また、その関節ステイフネスを肩関節筋、肘関節筋、2関節筋の成分に分解し、その成分にスケーリングパラメータをかけて、運動中のステイフネスを仮定している。このスケーリングパラメータは個々の運動によって異なるが、それらは、躍度最小軌道を目標軌道としたとき実現される軌道（これは腕のダイナミクスと、ステイフネスにより決まる）が、人間の運動の計測結果と合うように1から3倍の間でヒューリスティックに設定されている。（本論文で示した実験と同じような運動では、2.5倍程度に設定されている。）

座標系の違い、姿勢の違いのために、単純に本論文の計測値と比較することが出来ないため、Flashの計測値（静止時）と同等のMussa-Ivaldiら³⁶⁾の静止時の際の計測値と本論文で報告した値を、同じような姿勢の場合で比較すると、387[Nm]（Mussa-Ivaldi(文献36) page 2737中のReference position でのKyy値(本論文とx,yが逆の座標系設定))と160[N/m]（波打った摂動(pattern B)による計測）となり、本論文で示した計測値の方が半分以下になる。本論文の中で示す計測結果では、運動中のステイフネスは静止時と同程度かそれより低いいため、結局Flashは、本論文の中で示した運動中のステイフネスに比べて5倍以上大きな運動中のステイフネスを仮定してシミュレーションしたことになる。

2-C 係数の最小二乗推定

係数の推定を行うためには十分励振された、すなわちsufficient richness条件¹²⁷⁾を満たすデータが必要となる。平均化したデータからの推定を行うために推定時刻の前後のデータを使った。よって式(2-7)の各係数行列の要素の値は、

$$D = \begin{bmatrix} \delta\ddot{x}(t-n) & \delta\ddot{y}(t-n) & \delta\dot{x}(t-n) & \delta\dot{y}(t-n) & \delta x(t-n) & \delta y(t-n) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \delta\ddot{x}(t) & \delta\ddot{y}(t) & \delta\dot{x}(t) & \delta\dot{y}(t) & \delta x(t) & \delta y(t) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \delta\ddot{x}(t+n) & \delta\ddot{y}(t+n) & \delta\dot{x}(t+n) & \delta\dot{y}(t+n) & \delta x(t+n) & \delta y(t+n) \end{bmatrix} \quad (2-C-1)$$

$$\hat{H}(t) = [\hat{M}_{xx}(t), \hat{M}_{xy}(t), \hat{B}_{xx}(t), \hat{B}_{xy}(t), \hat{K}_{xx}(t), \hat{K}_{xy}(t)]^T \quad (2-C-2)$$

$$U = [\delta F_{ext_x}(t-n), \dots, \delta F_{ext_x}(t), \dots, \delta F_{ext_x}(t+n)]^T \quad n = 75 \quad (2-C-3)$$

として、

$$\hat{H} = (D^T D)^{-1} D^T U \quad (2-C-4)$$

により、求められる。ただし、 \wedge は各々の推定値を表す。

第3章付録

3-A Multi Layerd Perceptron (MLP) の学習アルゴリズム

MLPを第3章で説明した学習に用いた場合、シナプス荷重の調整則である式(3-8)の $(\partial\Phi/\partial w)^T$ の項は次のように計算できる。

m 層のMLPにおいて k 層の第 q ユニットへの入力の総和を i_q^k 、出力を o_q^k とし、 $k-1$ 層の第 p ユニットから k 層の第 q ユニットへのシナプス荷重を $w_p^{k-1,k}$ と表す。各ユニットの入出力関係を与える関数を h_k とおくと、それらの変数の関係は次のように表せる⁴⁾。

$$\begin{aligned}
 o_q^k &= h_k(i_q^k) \\
 i_q^k &= \sum_p w_{p,q}^{k-1,k} o_p^{k-1}
 \end{aligned} \tag{3-A-1}$$

よって、式(3-8)で、 $m-1$ 層の第 p ユニットから m 層の第 q ユニットへのシナプス荷重 $w_{p,q}^{m-1,m}$ の変化則だけを抜き出して書くと、式(3-A-2)の様になる。

$$\frac{dw_{p,q}^{m-1,m}}{dt} = \eta^{m-1,m} \frac{\partial \Phi}{\partial w_{p,q}^{m-1,m}} \tau_{q,imag} = \eta^{m-1,m} \frac{\partial i_q^m}{\partial w_{p,q}^{m-1,m}} \frac{\partial h_m}{\partial i_q^m} \tau_{q,imag} \tag{3-A-2}$$

ここで、

$$\frac{\partial h_m}{\partial i_q^m} \tau_{q,imag} = d_q^m \tag{3-A-3}$$

と表す。すると、 m 層目の各々の出力に対する $w_{p,q}^{k-1,k}$ での偏微分（ベクトル）と m 層目の各々の出力に与えられる τ_{imag} （ベクトル）を考えれば、 k 層目のシナプス荷重 $w_{p,q}^{k-1,k}$ の変化則は、

$$\frac{dw_{p,q}^{k-1,k}}{dt} = \eta^{k-1,k} \left(\frac{\partial \Phi}{\partial w_{p,q}^{k-1,k}} \right)^T \tau_{imag} = \eta^{k-1,k} \frac{\partial i_q^k}{\partial w_{p,q}^{k-1,k}} d_q^k \tag{3-A-4}$$

と表すことができる。ただし、

$$d_q^k = \frac{\partial h_k}{\partial i_q^k} \sum_r \left(\frac{\partial i_r^{k+1}}{\partial h_k} d_r^{k+1} \right) \tag{3-A-5}$$

である。これは、 $\tau_{imag} (= \tau_c + \tau_{ext})$ を各重みに対して割り振られるように逆伝播させるため、逆伝播法(back-propagation)³⁾と呼ばれ、 τ_{imag} が誤差信号の役割を果たしていることがわかる。また、この学習則で $m=2$ かつ h に線形関数を用いたとき、Widrow-Hoffの学習則となる。

3-B 逆モデル学習の収束性の検討

ここでは、確率空間でLyapunovの第2の方法とGemanの定理¹²⁸⁾を使って、逆モデル学習の収束性を検討する。

まず、本文中に記載した仮定を再度挙げる。

条件1：学習速度係数 η は非常に小さな固有値を持つ正定行列。

条件2： τ_{ext} と $\ddot{\theta}_r$ は十分なめらかで、かつ強混合・強定常過程である。

条件3：従来型のフィードバック制御器(CFC)は $\tau_{ext} = 0$ のとき、常に θ を θ_r に漸近的に収束させる機能を有する。

これらの仮定の下に、式(3-5)と式(3-8)の代わりに、次の確率微分方程式を使う。

$$f(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) - \Phi(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega)) \\ = K_2(\ddot{\theta}_r(t, \omega) - \ddot{\theta}(t, \omega)) + K_1(\dot{\theta}_r(t, \omega) - \dot{\theta}(t, \omega)) + K_0(\theta_r(t, \omega) - \theta(t, \omega)) + \tau_{ext}(t, \omega) \quad (3-B-1)$$

$$\frac{dw(t, \omega)}{dt} = \eta \left(\frac{\partial \Phi(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega))}{\partial w} \right)^T \\ \times \left\{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), \ddot{\theta}_r(t, \omega), \dot{\theta}_r(t, \omega), \theta_r(t, \omega)) + \tau_{ext}(t, \omega) \right\} \quad (3-B-2)$$

ここで、 ω は確率空間での1サンプル点である。さて、Gemanの定理¹²⁸⁾を考えると、学習係数 η が十分小さいとき、すなわち w の変化が θ の変化に比べ十分遅いとき式(3-B-2)の解はその平均化方程式(3-B-3)の解によって平均収束の意味でよく近似されることから、式(3-B-3)の解の収束性に関し以下で検討する。

$$\frac{dM}{dt} = \eta E \left[\left(\frac{\partial \Phi(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega))}{\partial w} \right)^T \right. \\ \left. \times \left\{ \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), \ddot{\theta}_r(t, \omega), \dot{\theta}_r(t, \omega), \theta_r(t, \omega)) + \tau_{ext}(t, \omega) \right\} \right]_{w=M} \quad (3-B-3)$$

平均化方程式のリアプノフ関数の候補として式(3-B-4)に示す関数 V を考える。各変数は全て確率空間の1サンプル点であるが、煩雑になるため、以下の式において (t, ω) は省略する。

$$V(M, t) = E \left[\frac{1}{2} \left\{ \tau_c(\ddot{\theta}, \dot{\theta}, \theta, \ddot{\theta}_r, \dot{\theta}_r, \theta_r) + \tau_{ext} \right\}^T \times \left\{ \tau_c(\ddot{\theta}, \dot{\theta}, \theta, \ddot{\theta}_r, \dot{\theta}_r, \theta_r) + \tau_{ext} \right\} \right]_{w=M} \quad (3-B-4)$$

V の時間微分は次のようになる。

$$\begin{aligned} & \frac{dV(M,t)}{dt} \\ & = E \left[(\tau_c + \tau_{ext})^T \left\{ \frac{\partial \tau_c}{\partial \ddot{\theta}} \frac{d\ddot{\theta}}{dt} + \frac{\partial \tau_c}{\partial \dot{\theta}} \frac{d\dot{\theta}}{dt} + \frac{\partial \tau_c}{\partial \theta} \frac{d\theta}{dt} + \frac{\partial \tau_c}{\partial \ddot{\theta}_r} \frac{d\ddot{\theta}_r}{dt} + \frac{\partial \tau_c}{\partial \dot{\theta}_r} \frac{d\dot{\theta}_r}{dt} + \frac{\partial \tau_c}{\partial \theta_r} \frac{d\theta_r}{dt} + \frac{d\tau_{ext}}{dt} \right\} \right]_{w=M} \end{aligned} \quad (3-B-5)$$

ここで,

$$\frac{\partial \tau_c}{\partial \ddot{\theta}} = -K_2, \quad \frac{\partial \tau_c}{\partial \dot{\theta}} = -K_1, \quad \frac{\partial \tau_c}{\partial \theta} = -K_0, \quad \frac{\partial \tau_c}{\partial \ddot{\theta}_r} = K_2, \quad \frac{\partial \tau_c}{\partial \dot{\theta}_r} = K_1, \quad \frac{\partial \tau_c}{\partial \theta_r} = K_0 \quad (3-B-6)$$

である。また、式(3-B-1)より、 $\ddot{\theta}$ は次のように表すことができる。

$$\ddot{\theta}(t, \omega) = h(\dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega), \ddot{\theta}_r(t, \omega), \dot{\theta}_r(t, \omega), \theta_r(t, \omega), \tau_{ext}(t, \omega)) \quad (3-B-7)$$

$\ddot{\theta}$ の時間微分は、式(3-B-7)の全ての変数を介して行う必要があることを考慮し、式(3-B-6)を使って式(3-B-5)を書き換えると次式のようにになる。

$$\begin{aligned} & \frac{dV}{dt} \\ & = E \left[(\tau_c + \tau_{ext})^T \left\{ -K_2 \left(\frac{\partial \ddot{\theta}}{\partial w} \frac{dw}{dt} + \frac{\partial \ddot{\theta}}{\partial \dot{\theta}} \frac{d\dot{\theta}}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta} \frac{d\theta}{dt} + \frac{\partial \ddot{\theta}}{\partial \ddot{\theta}_r} \frac{d\ddot{\theta}_r}{dt} \right. \right. \right. \\ & \left. \left. + \frac{\partial \ddot{\theta}}{\partial \dot{\theta}_r} \frac{d\dot{\theta}_r}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta_r} \frac{d\theta_r}{dt} + \frac{\partial \ddot{\theta}}{\partial \tau_{ext}} \frac{d\tau_{ext}}{dt} \right) - K_1 \frac{d\dot{\theta}}{dt} - K_0 \frac{d\theta}{dt} + K_2 \frac{d\ddot{\theta}_r}{dt} + K_1 \frac{d\dot{\theta}_r}{dt} + K_0 \frac{d\theta_r}{dt} + \frac{d\tau_{ext}}{dt} \right\} \right]_{w=M} \end{aligned} \quad (3-B-8)$$

式(3-B-8)の右辺を、 w を介する項とそれ以外の項に分けると、

$$\begin{aligned} \frac{dV}{dt} & = E \left[(\tau_c + \tau_{ext})^T \left\{ -K_2 \frac{\partial \ddot{\theta}}{\partial w} \frac{dw}{dt} \right\} \right]_{w=M} \\ & + E \left[(\tau_c + \tau_{ext})^T \left\{ -K_2 \left(\frac{\partial \ddot{\theta}}{\partial \dot{\theta}} \frac{d\dot{\theta}}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta} \frac{d\theta}{dt} + \frac{\partial \ddot{\theta}}{\partial \ddot{\theta}_r} \frac{d\ddot{\theta}_r}{dt} + \frac{\partial \ddot{\theta}}{\partial \dot{\theta}_r} \frac{d\dot{\theta}_r}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta_r} \frac{d\theta_r}{dt} + \frac{\partial \ddot{\theta}}{\partial \tau_{ext}} \frac{d\tau_{ext}}{dt} \right) \right. \right. \\ & \left. \left. - K_1 \frac{d\dot{\theta}}{dt} - K_0 \frac{d\theta}{dt} + K_2 \frac{d\ddot{\theta}_r}{dt} + K_1 \frac{d\dot{\theta}_r}{dt} + K_0 \frac{d\theta_r}{dt} + \frac{d\tau_{ext}}{dt} \right\} \right]_{w=M} \end{aligned} \quad (3-B-9)$$

式(3-B-9)の右辺第2項目の $E[\cdot]$ は、 $\ddot{\theta}, \dot{\theta}, \theta, \ddot{\theta}_r, \dot{\theta}_r, \theta_r, \tau_{ext}$ が強定常強混合過程であり、かつ w の変化速度は η を小さくするために非常に遅い場合は期待値が零になる。その理由は以下のとおりである。

式(3-B-9)第2項目は、次式のように M が一定の時の dV/dt の値と同じである。

$$\begin{aligned} \frac{dV_{M \text{ const}}}{dt} = E \left[(\tau_c + \tau_{ext})^T \left\{ -K_2 \left(\frac{\partial \ddot{\theta}}{\partial \dot{\theta}} \frac{d\dot{\theta}}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta} \frac{d\theta}{dt} + \frac{\partial \ddot{\theta}}{\partial \dot{\theta}_r} \frac{d\dot{\theta}_r}{dt} + \frac{\partial \ddot{\theta}}{\partial \theta_r} \frac{d\theta_r}{dt} + \frac{\partial \ddot{\theta}}{\partial \tau_{ext}} \frac{d\tau_{ext}}{dt} \right) \right. \right. \\ \left. \left. - K_1 \frac{d\dot{\theta}}{dt} - K_0 \frac{d\theta}{dt} + K_2 \frac{d\dot{\theta}_r}{dt} + K_1 \frac{d\theta_r}{dt} + K_0 \frac{d\tau_{ext}}{dt} + \frac{d\tau_{ext}}{dt} \right\} \right] \end{aligned} \quad (3-B-10)$$

強定常過程のBaire関数の期待値は時間に依存しない¹²⁹⁾。 $\ddot{\theta}, \dot{\theta}, \theta$ は強定常過程 $\ddot{\theta}_r, \dot{\theta}_r, \theta_r, \tau_{ext}$ のBaire関数であるから $V_{M \text{ const}}$ は時間に依存せず、よって $dV_{M \text{ const}}/dt$ は零となる。結局、式(3-B-9)は次式になる。

$$\frac{dV}{dt} = E \left[(\tau_c + \tau_{ext})^T \left\{ -K_2 \frac{\partial \ddot{\theta}}{\partial w} \right\} \frac{dw}{dt} \right]_{w=M} \quad (3-B-11)$$

さて、式(3-B-1)を参照して、式(3-B-7)を w で偏微分すると次式を得る。

$$\frac{\partial \ddot{\theta}}{\partial w} = \left(\frac{\partial f}{\partial \ddot{\theta}} - \frac{\partial \Phi}{\partial \ddot{\theta}} + K_2 \right)^{-1} \frac{\partial \Phi}{\partial w} \quad (3-B-12)$$

式(3-B-12)と式(3-B-2)を式(3-B-11)に代入すると、

$$\frac{dV}{dt} = E \left[-(\tau_c + \tau_{ext})^T K_2 \left(\frac{\partial f}{\partial \ddot{\theta}} - \frac{\partial \Phi}{\partial \ddot{\theta}} + K_2 \right)^{-1} \frac{\partial \Phi}{\partial w} \eta \left(\frac{\partial \Phi}{\partial w} \right)^T (\tau_c + \tau_{ext}) \right]_{w=M} \quad (3-B-13)$$

ここで、

$$A = K_2 \left(\frac{\partial f}{\partial \ddot{\theta}} - \frac{\partial \Phi}{\partial \ddot{\theta}} + K_2 \right)^{-1} \frac{\partial \Phi}{\partial w} \eta \left(\frac{\partial \Phi}{\partial w} \right)^T \quad (3-B-14)$$

と置いて、

$$B = \frac{A + A^T}{2} \geq 0 \quad (3-B-15)$$

という条件が学習中満たされているならば,

$$\frac{dV}{dt} \leq 0 \quad (3-B-16)$$

を得る. ニューラルネットワークの学習がローカルミニマムに陥らなければ, すなわち最適点以外で $\partial\Phi/\partial w \neq 0$ であれば, 等号成立のとき V は最小値になる. すなわち, 3.2.1 で仮定した神経回路モデルの関数近似能力がある場合は, 式(3-8)の適応則を実行することにより, 式(3-4)が成立し, 式(3-9)を満たす応答が得られる.

式(3-B-15)は収束のための単なる十分条件であるため, それ以外の条件でも収束する可能性はある. 制御対象の慣性行列を学習中知ることができる場合は, 学習則を,

$$\frac{dw}{dt} = \eta \left(\frac{\partial\Phi}{\partial w} \right)^T \left(K_2 \left(\frac{\partial f}{\partial \theta} - \frac{\partial\Phi}{\partial \theta} + K_2 \right)^{-1} \right)^T (\tau_c + \tau_{ext}) \quad (3-B-17)$$

とすることにより, 式(3-B-15)の条件によらずに収束を得ることができる.

3-C 非線形レギュレータ学習の収束性の検討

逆モデル学習の収束性の検討の場合と同じ仮定の基に, 式(3-14)(3-24)を, 次の2つの確率微分方程式で置き換える.

$$\begin{aligned} & R(\theta(t, \omega))\dot{\theta}(t, \omega) + N(\theta(t, \omega), \dot{\theta}(t, \omega)) \\ & = \Phi(\ddot{\theta}_r(t, \omega), \dot{\theta}_r(t, \omega), \theta_r(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega)) \\ & \quad + K_2(\ddot{\theta}_r(t, \omega) - \ddot{\theta}(t, \omega)) + K_1(\dot{\theta}_r(t, \omega) - \dot{\theta}(t, \omega)) + K_0(\theta_r(t, \omega) - \theta(t, \omega)) \end{aligned} \quad (3-C-1)$$

$$\frac{dw(t, \omega)}{dt} = \eta \left(\frac{\partial\Phi(\ddot{\theta}_r(t, \omega), \dot{\theta}_r(t, \omega), \theta_r(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega))}{\partial w} \right)^T \times \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) \quad (3-C-2)$$

ここで, ω は確率空間での1サンプル点である. さて, 付録3-Bと同様, Gemanの定理

¹²⁸⁾を考えると、学習係数 η が十分小さいときすなわち w の変化が θ の変化に比べ十分遅いとき式(3-C-2)の解はその平均化方程式(3-C-3)の解によって平均収束の意味でよく近似されることから、式(3-C-3)の解の収束性に関し以下で検討する。

$$\frac{dM}{dt} = \eta \times E \left[\left(\frac{\partial \Phi(\ddot{\theta}_r(t, \omega), \dot{\theta}_r(t, \omega), \theta_r(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega), w(t, \omega))}{\partial w} \right)^T \times \tau_c(\ddot{\theta}(t, \omega), \dot{\theta}(t, \omega), \theta(t, \omega)) \right]_{w=M} \quad (3-C-3)$$

まず式(3-C-4)に示す関数 P を用いて、平均化方程式のリアプノフ関数の候補として式(3-C-5)に示す関数 J を考える。各変数は全て確率空間の1サンプル点であるが、煩雑になるため、以下の式において (t, ω) は省略する。

$$P = \Phi - [N(\theta, \dot{\theta}) + R(\theta)\ddot{\theta}_r + R(\theta)K_2^{-1}(K_1(\dot{\theta}_r - \dot{\theta}) + K_0(\theta_r - \theta))] \quad (3-C-4)$$

$$J(M) = E \left[\frac{1}{2} P^T P \right]_{w=M} \quad (3-C-5)$$

J を時間微分し、 w を媒介変数として時間で微分される項とそれ以外の項に分け、次のように表す。

$$\frac{dJ}{dt} = E \left[P^T \frac{dP}{dt} \right]_{w=M} = E \left[P^T \frac{\partial \Phi}{\partial w} \frac{dw}{dt} \right]_{w=M} + \frac{dJ}{dt} \quad (3-C-6)$$

ただし、

$$\frac{dJ}{dt} = E \left[P^T \left\{ \sum_{k=0}^1 \frac{\partial P}{\partial \left(\frac{d^k \theta}{dt^k} \right)} \frac{d \left(\frac{d^k \theta}{dt^k} \right)}{dt} + \sum_{k=0}^2 \frac{\partial P}{\partial \left(\frac{d^k \theta_r}{dt^k} \right)} \frac{d \left(\frac{d^k \theta_r}{dt^k} \right)}{dt} \right\} \right]_{w=M} \quad (3-C-7)$$

ここで、

$$\Phi = \tau_n = \tau - \tau_c \quad (3-C-8)$$

$$N(\theta, \dot{\theta}) = \tau - R(\theta)\ddot{\theta} \quad (3-C-9)$$

より、

$$P = -(I + R(\theta)K_2^{-1})\tau_c \quad (3-C-10)$$

となることと、 w の適応則が式(3-C-2)であることを考慮すると、式(3-C-6)は次式で表せる。

$$\frac{dJ}{dt} = E \left[-\tau_c^T (I + R(\theta)K_2^{-1})^T \frac{\partial \Phi}{\partial w} \eta \frac{\partial \Phi}{\partial w} \tau_c \right]_{w=M} + \frac{dJ}{dt} \quad (3-C-11)$$

式(3-C-11)第2項目は、 w を固定したときの J の平均的な時間変化を表すが、 $\dot{\theta}_r$ が強定常（すなわち $\dot{\theta}_r, \theta_r$ も強定常）であり、また J はそのBaire関数と見れるため J は時間に依存せず一定値となる。よって、

$$\frac{dJ}{dt} = 0 \quad (3-C-12)$$

ここで、

$$C = (R(\theta)K_2^{-1})^T \frac{\partial \Phi}{\partial w} \eta \frac{\partial \Phi}{\partial w} \quad (3-C-13)$$

とおくとき、

$$D = \frac{C + C^T}{2} \geq 0 \quad (3-C-14)$$

という条件が学習中満たされているならば、

$$\frac{dJ}{dt} \leq 0 \quad (3-C-15)$$

となる。よって、神経回路モデルの学習がローカルミニマムに陥らなければ、すなわち最適点以外で $\partial \Phi / \partial w \neq 0$ であれば、等号成立のとき J は最小値になる。また、使用する神経回路モデルが十分な関数近似能力を持つならば、 $\Phi \rightarrow \Phi_d$ となり、式(3-17)が成立し、式(3-19)を満たす応答が得られる。

対象の慣性行列が学習中知ることができる場合は、学習則を、

$$\frac{dw}{dt} = \eta \left(\frac{\partial \Phi}{\partial w} \right)^T (I + R(\theta)K_2^{-1})\tau_c \quad (3-C-16)$$

とすることにより，式(3-C-14)の条件によらずに収束を得ることができる。

3-D マニピュレータのインピーダンス制御

Hoganによってまとめられたマニピュレータのインピーダンス制御は，いくつかの実現方法がある．ここでは，フィードバック信号として力センサ情報，位置，速度情報を用いてインピーダンス制御を実現するHoganの方法⁷²⁾と，力センサ情報を使わずに加速度情報を使ってインピーダンス制御を実現する方法⁷⁷⁾の関係を説明する．

まず，多関節マニピュレータの運動方程式と規範インピーダンスの式を再度定義する．

$$R(\theta)\ddot{\theta} + N(\theta, \dot{\theta}) = \tau + J^T F_{ext} \quad (3-D-1)$$

$$M(\ddot{x} - \ddot{x}_r) + B(\dot{x} - \dot{x}_r) + K(x - x_r) = F_{ext} \quad (3-D-2)$$

ここで， R は慣性行列， N は速度，位置に関する項， τ はアクチュエータによって入力されるトルク， J^T は関節角からマニピュレータ先端位置への変換のヤコビ行列， F_{ext} はマニピュレータ先端に加わる外力， $\theta, \dot{\theta}, \ddot{\theta}$ は関節位置・速度・加速度， x, \dot{x}, \ddot{x} はマニピュレータ先端位置・速度・加速度， $x_r, \dot{x}_r, \ddot{x}_r$ は参照位置・速度・加速度である．

さてここで，

$$\tau = R(\theta)\ddot{\theta} + N(\theta, \dot{\theta}) - J^T (M(\ddot{x} - \ddot{x}_r) + B(\dot{x} - \dot{x}_r) + K(x - x_r)) \quad (3-D-3)$$

となるようにフィードバック補償を与えると， M, B, K を実現可能な範囲で設定することで希望する作業座標系でのインピーダンスを得ることができる．これは，加速度情報を使ったインピーダンス制御である．

次に，式(3-D-3)の加速度の項を，力センサで検出した情報を使うことを想定し次式で置き換える．

$$\ddot{\theta} = R^{-1}(\tau + J^T F_{ext} - N) \quad (3-D-4)$$

$$\ddot{x} = J\ddot{\theta} + \dot{J}\dot{\theta} = JR^{-1}(\tau + J^T F_{ext} - N) + \dot{J}\dot{\theta} \quad (3-D-5)$$

式(3-D-4), (3-D-5)を式(3-D-3)に代入して整理すると, 次式を得る.

$$\tau = RJ^{-1}M^{-1}(M\ddot{x}_r + B\dot{x}_r + K(x_r - x) - BJ\dot{\theta}) + N - RJ^{-1}\dot{J}\dot{\theta} + (RJ^{-1}M^{-1} - J^T)F_{ext} \quad (3-D-6)$$

この式で, 参照入力 velocity・加速度項, \dot{x}_r, \ddot{x}_r , を0と置くと, Hoganの定式化と同様になる. すなわち, 両方式の違いは, インピーダンス制御に必要な情報をどのような形で入力するかによる違いであると言える. 実際に実現するに当たっては, どちらの方式も制御対象のダイナミクスに関する知識を必要とする. また実現される性能 (インピーダンスの可調整範囲) はセンサの性能や使用するフィルタに依存するため, どちらが優れているかを一概に言うことはできない. ただし, 加速度信号をエンコーダを使って検出する場合, 低いカットオフ周波数 (10-50[Hz]) のフィルタを用いることになるため, 周波数特性の限界が比較的低くなってしまふことになる.

第4章付録

4-A 小脳 Smith predictor 説

最近Miallら⁹³⁾は, 図3の破線囲み部分(B)の様に「小脳では運動の順モデルを使って, 視覚や体性感覚の信号伝達系の遅れを補償する機能を実現している」という計算モデルを提案し, 呈示された指標をレバーを動かして追跡させる実験(manual tracking task experiment)における”観測むだ時間要素(Observer dead time)”の影響を再現した. このモデルは, 図3の(A)部分に示すように, 川人らの逆モデルを使った制御モデルと容易に融合することができる.

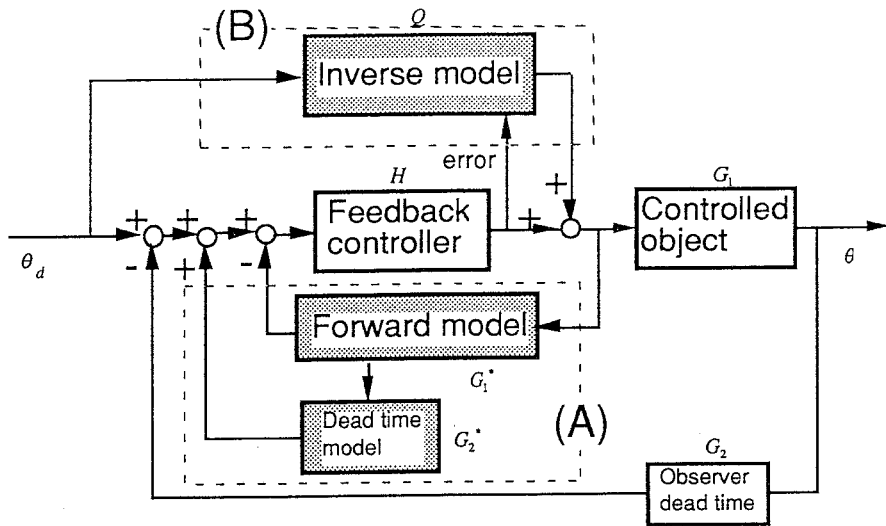


Fig. 4-A.1 Learning motor control by cerebellum with internal model of controlled object.
 (A) Compensatory control by the forward model of a controlled object proposed by Miall.
 (B) Compensatory control by the inverse model of controlled object.

上図で、Controlled object を G_1 、Observer dead time を G_2 、Forward model を G_1^* 、Dead time model を G_2^* 、Feedback controller を H で表し、 $G_1 = G_1^*$ 、 $G_2 = G_2^*$ であるとする、上のブロック図は、Fig.4-A.2 の様 書き換えられる。すなわち、フィードバック誤差学習によって獲得されるものは、制御対象の観測遅れを含まない G_1 だけの逆モデルになる。Miall らのモデルでは、順モデルや遅れ(dead time)の学習がどのように行われているかということに関して十分考察されていないが、制御対象である四肢の(順、逆)内部モデルに基づく制御が小脳で行われているという考え方を支持するものである。

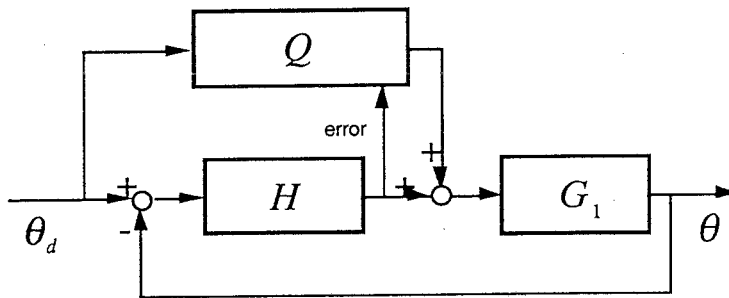


Fig. 4-A.2 Transformed block diagram of the combined scheme of feedback-error-learning and Smith predictor.

4-B フィードバック誤差学習を検証するために提案する生理実験

Fig.4-B.1に示すように、サルの小脳外側部に電極を入れ、プルキンエ細胞での複雑スパイクから登上線維の発火パターンが観察できるようにする。そのサルに腕の位置を計測できる装置（マニピュランダム等）を握らせ、ハンドルの動きに応じてディスプレイ上を動くHand cursorを表示し、サルには自分の実際の腕がどのような状況にあるかは見えないようにする。そしてこのHand cursorをディスプレイに投影されるスタート位置から任意のターゲット t にうまく移動させるような運動を学習させる。このとき、start位置から t_1 への移動中に t_2 を表示し、 t_2 へ向かう運動に切り替させるような操作を行う。このような「ターゲットチェンジ」を行うのは、誤差の符号が実験的に制御できるためである¹³⁰⁾。Hand cursorは、normal状態で手の動きと同じ方向へディスプレイ上を動くよう設定し、mirror状態で手の動きと逆の方向に動くよう設定する。normalからmirrorに状態が移ったとき、サルはカーソルをターゲットに動かすための運動を再学習しなければならない。各状態において同程度の運動誤差が出ているときの登上線維の発火パターンを見たとき、もし登上線維が軌道誤差(trajec-tory error)をコードしていたとするとその発火パターンはnormal とmirrorの状態に変化がなく、運動司令誤差(command error)であるなら、発火パターンが大きく変化するはずである。すなわち、この実験によって、プルキンエ細胞の信号伝達効率の変化を誘発する下オリーブ核からの信号が、どちらの空間で表されているかを見ることができる。

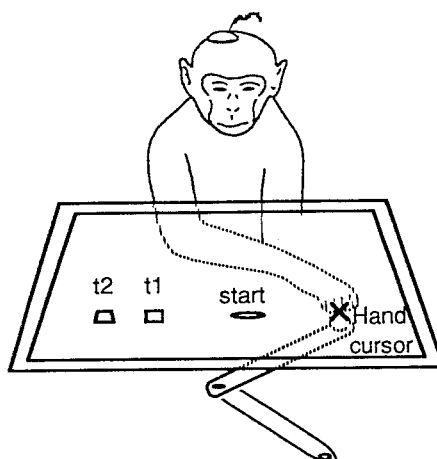


Fig. 4-B.1 Proposed target-change experiment under normal and mirror-image coordinate transformations which reveals the reference coordinates in which climbing-fiber responses are represented.

4-C VOR小脳適応説における生理学データの矛盾


VORの際のプルキンエ細胞の挙動は、ウサギやサルを対象とした電気生理実験で多く観察された。伊藤、永雄らのウサギを対象とした実験¹³⁹⁷⁾では、(1)小脳片葉が前庭器官入力を主としており、(2)プルキンエ細胞の前庭器官の活動に対してのゲインが上がるとVORゲインは下がり、(3)水平前庭動眼反射に関わる片葉への登上線維信号は網膜のイメージのぶれを伝え、片葉破壊で適応変化がなくなることが報告されている。一方、Milesら¹³¹⁾、Lisberger¹³²⁾のサルを対象とした実験では、これらの結果に反する報告がなされた。最近種に依存した脳の部位が細かく研究され、Miles、Lisbergerらの調べていた部位は、解剖学的に傍片葉と言われる新小脳に属する部位であることが明らかにされ、サルの片葉に当たる部位でのプルキンエ細胞の活動はウサギの実験と矛盾しない結果が得られている。

また、Llinasら¹³³⁾は、プルキンエ細胞へ登上線維信号を送る下オリーブ核の破壊によって、以前学習した結果も失われてしまうことを示したが、下オリーブ核を破壊するとプルキンエ細胞も変性を起こし通常の学習状態と変わってしまうことから、下オリーブ核の破壊が単に学習を止めて記憶を保存させておくことにならないことが伊藤らの研究により示された。

以上の生理学的研究結果の矛盾点は、文献1,98に詳しい。

4-D 前庭器官からの信号、誤差信号および運動指令の座標系

VOR（前庭動眼反射）の適応に関係する座標系は、Fig.4-D.1に示すように3つある。1つは半規管から送られる頭部運動の信号の座標系である。2つ目は運動を発生する眼筋の座標系である。眼球を動かす筋肉の座標系と半器官の座標系が異なっていることは以前から指摘され、そのため半器官から運動司令への信号の座標変換モデル¹³⁴⁾などが提案されている。



半器官の座標系

眼筋の運動座標系

下オリーブ核での
信号座標系

Fig. 4-D.1 Three coordinate frames for VOR adaptation

Anastasioらは近年，神経回路モデルを用いた前庭動眼反射の学習系モデルを組んでいるが^{135,136,137)}，そのモデルでは誤差の座標変換は誤差逆伝搬法によって解かれている。しかし，実際の生体系では網膜上で検出された誤差を誤差逆伝搬法で運動司令誤差に変換しているわけではなく，下オリーブ核を通り小脳片葉に伝搬される信号によりプルキンエ細胞の信号伝達効率が変化する様な仕組みになっている²⁶⁾。本文中で述べたように，下オリーブ核からの信号がフィードバック誤差に相当するのであれば，下オリーブ核から供給される信号も運動座標系で表されていなければならない。下オリーブ核から来る信号の座標系が運動の座標系と一致していないと学習がうまく進行しない事になる。以上の理由により，下オリーブ核からの信号の座標系をVOR適応に関係する3つ目の座標系として考慮する。

さて，Simpsonら⁹⁴⁾は片葉での複雑スパイクは網膜への刺激の方向によってその強さが異なることを調べ，それから得られた座標系が筋肉の配置から得られる運動方向の座標系とほぼ一致することを確認した。ウサギの眼筋の一部と半器官の一部を水平面に射影した配置構成をFig.4-D.2(a)に示す。斜筋(Oblique)の上下のペア，上下の直筋(Recti)は，それぞれ筋の収縮方向に直交する軸周りの回転をつかさどる。半規管は半規管のリングの面に直交する軸まわりの運動を検出する。




Fig. 4-D.2 (a) Geometry of eye muscles and semicircular canals of a rabbit.
 (b) Geometrical axes of IO signal, muscles and semicircular canals in left eye.

Simpsonら⁹⁴⁾の実験結果が左右対称になると仮定して、単眼(左)についての眼筋回転軸と下オリーブ核から片葉に投射される信号の回転座標軸、そして半器官から得られる信号の回転軸を各々水平面に射影したものをFig.4-D.2 (b)に示す。太線は各々の主成分の回転軸を表している。運動回転座標軸と下オリーブ核(IO)からの信号の回転座標軸および前方半器官(anterior canal)の回転座標軸はほぼ一致しているが、後方半器官(posterior canal)からの信号の回転座標軸に対応するものは下オリーブ核からの信号にない⁹⁴⁾。

下オリーブ核からの信号の座標軸が感覚座標軸とでなく運動座標軸と一致することは計算論的に考えると必要事項であるが、Fig.4-D.2に示したウサギの例では、下オリーブ核で表現されている座標軸が前方半器官と筋肉のどちらの座標軸とも近いので、下オリーブ核からの信号が半器官の座標系で表されているのではないことを確言できない。これは、ネコなどの三半器官と筋肉の座標系がはっきりと異なる動物⁹⁹⁾を使って下オリーブ核からの信号の座標系を計測することにより明確になる問題であると考えられる。

4-E 神経発振器と歩行運動

歩行運動におけるリズム形成や屈曲・伸展の切り替えは、反射の連鎖や歩行器官からの感覚入力であるフィードバックによってのみ動作しているのではなく、上位中枢から

の司令によっておこるとされている。これは、後根（フィードバック経路）を切断されたネコをトレッドミル（ベルトコンベアのようなもの）上で歩行させたときに、Ia抑制介在ニューロンとRenshaw細胞は律動的群発をするという現象¹¹⁰⁾などにより示され、神経システム自体でなんらかのリズム発生機構を構成していることがわかる。また、除脳ネコ（小脳あり、視床下核なし）や脊髓ネコにおいて中脳歩行誘発野(楔状核:nucleus cuneiformis)に刺激を加えると歩行が開始され、刺激の大きさにより歩容が変化し(Mori 1987)、正常ネコで楔状核の破壊により肢の協調動作、筋活動が乱れることは、中枢神経に存在すると考えられるリズム発生系が歩行運動において重要な役割をしていることを示してゐる。

4-F 下オリーブ核からの信号が誤差を表現していることを示唆する実験

Table 4-F.1 Experimental results which suggest IO (inferior olive) signal encodes performance or motor-command error

著者	種, 部位	実験から得られた内容
Simpson & Alley (1974)	ウサギ 片葉	CSがretinal slipの方向と大きさにある程度比例することを示した。
Simpson, Graf & Leonard (1989)	ウサギ 片葉	CSの反応がretinal slipの方向によって異なり、筋肉の座標系に近い座標系を持つことを示した。
Udo et al. (1983)	ネコ 虫部	歩行中、前肢に外乱を与えた直後にCSが発生することを示した。
Gilbert & Thach(1977)	サル 外側部	手首運動で負荷を変えたとき、CSが発生すること、学習によって減少することを示した。

第5章付録

5-A 各データセットのトレース数と決定係数の関係

各データセットをアンサンブル平均で求めるために用いたトレースの数は、データセットによって異なる。そのため、特に発火頻度信号のダイナミックレンジが各々異なり、ノイズ成分の大小が決定係数に対して大きく影響を与える。即ち、トレース数が少ないものは、うまくモデリングできても決定係数が低くなるということが生ずる。Fig.5-A.1に各データセットのトレース数と決定係数の関係を示す。各黒点は、各々のデータセットにおける平均に用いたトレース数と決定係数との関係である。それらの関係には、それほど強い相関が現われていない。本解析には、正しく回帰分析を行うという観点から、運動成分（すなわち説明変数）に掛けたフィルタと同じものを発火頻度の信号（すなわち被説明変数）にも施したが、結果的に、このフィルタによりアンサンブル数の違いに起因するノイズ成分の分散の大きさの違いが与える決定係数への影響が、ある程度押さえられているものと考えられる。




Fig.5-A.1 Trace number for ensemble averaging V.S. coefficient of determination of each data set .

5-B 最小二乗法により求めた係数の推定誤差

発火頻度を再構成した際に求められた加速度，速度，位置の係数パラメータの推定精度に関して以下に説明する．本文中の解析では，ある短い時間（約300 msec）でパラメータの推定を行っているため，使用したモデルが正しいとしても，(1)観測した発火頻度と再構成した発火頻度との誤差が多少あり，かつ(2)入力信号間（位置，速度，加速度）の相関が高い場合には，係数パラメータの推定精度が悪くなる可能性がある．そこで，以下にこれらの関係を定式化する．

$f = (f_1, f_2, \dots, f_t)^T$	(t x 1)	P-cell firing frequency vector
$P = (M, B, K)^T$	(3 x 1)	Coefficient parameter vector
$Q = (\Theta_1, \Theta_2, \dots, \Theta_t)^T$	(t x 3)	motion results matrix (input matrix)
$\Theta_t = (\ddot{\theta}, \dot{\theta}, \theta)$	(1 x 3)	motion results vector

真の発火頻度 = 運動結果 X 真のパラメータ

$$f_0 = QP_0 \quad (5-B-1)$$

観測した発火頻度は，真値に各時点で独立の誤差が乗ったものと仮定する．

$$\hat{f} = f_0 + e = Q\hat{P} \quad (5-B-2)$$

パラメータの推定値は重み付誤差の最小自乗誤差条件より次式で求められる．

$$\hat{P} = Z\hat{f} \quad (5-B-3)$$

ここで，

$$Z = (Q^T W Q)^{-1} Q^T W$$

$$W = \sigma_0^2 \Sigma_f^{-1} \quad \text{重み行列}$$

$$\Sigma_{\hat{f}} = ee^T = \begin{bmatrix} \sigma_1^2 & & 0 \\ & \ddots & \\ 0 & & \sigma_t^2 \end{bmatrix} \quad (\text{誤差は各時点で独立と仮定})$$

よって、パラメータの誤差は、

$$\hat{P} - P_0 = \mathbf{Z}(\hat{f} - f_0) = \mathbf{Z}e \quad (5-B-4)$$

また、パラメータの誤差の分散共分散行列は、

$$\begin{aligned} \Sigma_{\hat{P}} &= (\hat{P} - P_0)(\hat{P} - P_0)^T \\ &= \mathbf{Z}ee^T\mathbf{Z}^T \\ &= (\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1}\mathbf{Q}^T\mathbf{W}\Sigma_{\hat{f}}((\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1}\mathbf{Q}^T\mathbf{W})^T \\ &= (\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1}\mathbf{Q}^T\mathbf{W}\Sigma_{\hat{f}}\mathbf{W}^T\mathbf{Q}((\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1})^T \\ &= (\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1}\mathbf{Q}^T\sigma_0^2\Sigma_{\hat{f}}^{-1}\Sigma_{\hat{f}}\mathbf{W}^T\mathbf{Q}((\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1})^T \\ &= \sigma_0^2(\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1}\mathbf{Q}^T\mathbf{W}^T\mathbf{Q}((\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1})^T \\ &= \sigma_0^2(\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1}(\mathbf{Q}^T\mathbf{W}\mathbf{Q})^T((\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1})^T \\ &= \sigma_0^2(\mathbf{Q}^T\mathbf{W}\mathbf{Q})^{-1} \\ &= (\mathbf{Q}^T\Sigma_{\hat{f}}^{-1}\mathbf{Q})^{-1} \end{aligned} \quad (5-B-5)$$

となる。

よって、 $\Sigma_{\hat{P}}$ の(i,i)要素を $\sigma_{\hat{P}_i}^2$ と書くと、パラメータの信頼区間は、

$$\hat{P}_i \pm t_{(\alpha/2)}\sigma_{\hat{P}_i} : (1-\alpha)\times 100\% \quad (5-B-6)$$

となる。ここで、 $t_{(\alpha/2)}$ はt-distributionの片側 $\alpha/2\%$ の確率。

以上よりパラメータの信頼区間に関して次に示す定性的性質が得られる。

1. パラメータの分散が小さいほど信頼区間は狭くなる。(推定値が信頼できるようになる)
2. 観測ノイズの大きさは、パラメータ信頼区間に反映される。(ノイズが大きいほど、信頼区間が広くなり、推定パラメータが信頼できる確率が減る)
3. 入力データのrichnessは、信頼区間に反映される。(入力信号に相関があればあるほど $\mathbf{Q}^T\mathbf{Q}$ の最小固有値は0に近くなり、その逆数に比例するパラメータの分散は大きくなり、すなわちパラメータの信頼性が悪くなる。)逆に、入力信号に強い相

関があっても、パラメータの信頼区間が狭ければ、パラメータ間に相関があったとしても、パラメータの絶対値はある程度信頼できることになる。

よって、入力信号の相関を見ることなく、パラメータの信頼区間を評価基準として、パラメータの信頼性を評価できる。

ここで、入力データの richness が信頼区間が有限に収まることの必要条件であることを述べる。

Sufficient richness (= Persistency of excitation (PE)) とは、

$Q^T Q \geq \alpha I$ なる正の数 α が存在する。 (Q は $t \times n$ 行列)

$\Rightarrow \text{rank}(Q^T Q) = n$ になる (n はパラメータ数)

ことである¹²⁷⁾。これが満たされない場合、すなわち $\text{rank}(Q^T Q) < n$ の場合、 $Q^T Q$ に零固有値が存在し、よって $Q^T \Sigma_f^{-1} Q$ にも零固有値が存在する。これを形式的に、無限に零に近い固有値と考えると、 $(Q^T \Sigma_f^{-1} Q)^{-1}$ に無限大固有値が存在することになり、この場合、あるパラメータの信頼区間が無限大に発散することになる。

以上より、データの richness は全てのパラメータの信頼区間が有限に収まることの必要条件になっていることが判る。

5-C 従来調べられたP-cell発火頻度と運動の関係との比較

従来、Milesら¹³⁸⁾、Stone & Lisberger⁸⁷⁾ は小脳傍片葉における追跡性眼球運動に反応するP-cell発火頻度と眼球速度との関係を調べている。Milesら¹³⁸⁾が調べた Eye-velocity sensitivity は平均で 1.02 (Ipsi) [(spike/sec)/(deg/sec)] であり、Stone & Lisberger⁸⁷⁾ では 1.34 (Down), 0.99 (Ipsi) [(spike/sec)/(deg/sec)] となっている (運動方向の取り方が今回とは逆であるため、各係数の符号が逆になっている)。これらの平均値は、今回得た速度係数とオーダは等しいが、平均値では3倍程度異なっている。また、fixation中の位置係数はMilesら¹³⁸⁾によると 0.26 (0.87 max) [(spike/sec)/deg] でありこれも今回得られた結果とは符号さえも異なっている。これらの差の理由としては、静止中と運動中の位置の寄与度の違いや、調べた運動の種類の違いが考えられる。

しかし、さらにMilesら¹³⁸⁾、Stone & Lisberger⁸⁷⁾の方法には2つの問題点がある。1つは、

なるべく1つの要因（加速度，速度，位置）だけが支配的になる状況を使ってその係数を計算しようと試みているにしろ，ある係数を求めるのにその他の成分を完全に排除することが不可能であり，係数推定を誤る可能性が大きいことである．もう1つは，異なった運動で各々の係数を推定しているため，解析対象の非線形性，あるいは他の部位から下流の神経回路への関わり方の変化などによって生ずる運動の種類ごとに異なる係数の変化を捕えることが出来ないということである．Stone & Lisberger⁸⁷⁾らの結果では発火頻度が眼球速度の位相に比べて平均で7 [deg]（周波数0.5[Hz]で動いているため，時間にすると38.9[msec]）も先行しており，これがすべて[発火→運動]潜時だとは考え難く，彼らが行ったように単に発火頻度と眼球速度の振幅比だけで速度係数の推定をすると大きく誤差が生じてしまうと考えられる．また，Milesら¹³⁸⁾はfixationしている間の位置の係数を使って，発火頻度から位置成分を除いて速度係数の修正を行っているが，上記の2つ目の理由により，運動中の速度係数に修正していることにはならない可能性がある．

これに対し，本論文で報告した方法は，発火頻度を各成分に分解し同時に各係数を推定するものであり，各成分が混在している場合でも解析波形が十分richでかつ使用するモデルが十分であれば，従来の手法と比べより正確な値が得られ，かつ対象とした種類の運動を遂行している間の係数を見ていることになる．また，求めた係数を使って再構成した発火パターンと観測波形との類似度を計算することにより，その線形表現と求めた係数の組み合わせが元の発火パターンをどれだけ表現できているかを確認することができ，求めた係数の信頼性を調べることも可能である．

今回解析したOFRの信号が十分richな波形であるか，推定係数がどの程度正確かは，5.4.1.(3)で調べた推定係数の信頼区間で検討できる（付録5-B参照）．得られた各係数の信頼区間は推定係数分散の数分の1程度に収まっており，推定係数の平均値はある程度信頼できるものとする．

5-D Cp統計量によるモデルの選択

以下に，(A)速度・位置・バイアスを用いたモデル，(B)加速度・速度・位置・バイアスを用いたモデル，(C)躍度・加速度・速度・位置・バイアスを用いたモデル，のどれが解析対象のデータに対して適切であるかを，Cp統計量によって調べた手順について述べる．Cp統計量は，

$$C_p = \frac{\sum (\hat{f}(t) - f(t))^2}{\hat{\sigma}^2} - n + 2p \quad (5-D-1)$$

で表される。ここで、 n はデータ数（1つのデータセットに含まれる）、 p はモデルの自由度、 $\hat{\sigma}^2$ は母数分散、 $\hat{f}(t)$ は個々のモデルで得られた発火頻度、 $f(t)$ は実際の発火頻度である。本解析では、 $\hat{\sigma}^2$ の推定値として最大自由度のモデル(C)の推定分散を用いて計算した。Cp統計量を、上記3つのモデル、すなわち $n=3, 4, 5$ の場合について、全データセットに対して個々に調べた。その結果、(B)のモデルがCp統計量が最低になるケースが全データセットの76.6% (72/94)となり、この基準から(B)のモデルが妥当であることが示された。

参考文献

- [1] Ito伊藤正男, 自然選書, 脳の設計図, 中央公論社, 1980.
- [2] Amari甘利俊一, システムサイエンスシリーズ, 神経回路網の数理, 産業図書, 1978.
- [3] D. E. Rumelhart and J. L. McClelland, *Parallel Distributed Processing*, The MIT Press, 1986.
- [4] Aso麻生, ニューラルネットワーク情報処理, 産業図書, 1987.
- [5] E. Bizzi, A. Polit and P. Morasso, "Mechanisms underlying achievement of final head position", *Journal of Neurophysiology*, Vol.39(No.2), 1976, pp. 435-444.
- [6] A. Polit and E. Bizzi, "Characteristics of motor programs underlying arm movements in monkeys", *Journal of Neurophysiology*, Vol.42(No.1), 1979, pp. 183-194.
- [7] E. Bizzi, N. Accornero, W. Chapple and N. Hogan, "Posture control and trajectory formation during arm movement.", *Journal of Neuroscience*, Vol.4(No.11), 1984, pp. 2738-2744.
- [8] N. Hogan, "An organizing principle for a class of voluntary movements", *Journal of Neuroscience*, Vol.4(No.11), 1984, pp. 2745-2754.
- [9] M. Kawato, K. Furukawa and R. Suzuki, "A hierarchical neural-network model for control and learning of voluntary movement", *Biological Cybernetics*, 57, 1987, pp. 169-185.
- [10] T. Flash and N. Hogan, "The coordination of arm movements: An experimentally confirmed mathematical model", *Journal of Neuroscience*, 5, 1985, pp. 1688-1703.
- [11] T. Flash, "The control of hand equilibrium trajectories in multi-joint arm movements", *Biological Cybernetics*, 57, 1987, pp. 257-274.
- [12] J. M. Winters, "Hill based muscle models: A systems engineering perspective", In J. M. Winters and S. L.-Y. Woo (eds.), *Multiple Muscle Systems: Biomechanics and Movement Organization*, New York, Springer-Verlag, 1990, pp. 69-93.
- [13] Yoshikawa吉川, ロボット制御基礎論, Tokyo: コロナ社, 1990.
- [14] C. H. An, C. G. Atkeson and J. M. Hollerbach, *Model-Based Control of a Robot Manipulator*, MA: MIT Press, 1988.
- [15] Y. Uno, M. Kawato and R. Suzuki, "Formation and control of optimal trajectory in human multijoint arm movement", *Biological Cybernetics*, 61, 1989, pp. 89-101.
- [16] Uno宇野, 鈴木 and 川人, "腕の運動軌道を再現する筋張力変化最小モデル", 計測自動制御学会 第4回 生体・生理工学シンポジウム, 1989, pp. 299-302.
- [17] M. Kawato, "Computational schemes and neural network models for formation and control of multijoint arm trajectory", In T. Miller III, R. S. Sutton and P. J. Werbos (eds.), *Neural networks for control*, Cambridge, Massachusetts, The MIT Press, 1990, pp. 192-228.
- [18] Wada和田 and 川人, "制御対象の順・逆モデルを含む神経回路網による腕の軌道生成", 電子情報通信学会論文誌, Vol.J75-D-II(5), 1992, pp. 991-999.
- [19] H. Miyamoto, M. Kawato, T. Setoyama and R. Suzuki, "Feedback-error-learning neural network for trajectory control of a robotic manipulator", *Neural Networks*, 1, 1988, pp. 251-265.

- [20] M. Kano, M. Kawato, Y. Uno and R. Suzuki, "Learning trajectory control of a redundant arm by feedback-error-learning", *IEICE technical report*, 89, 1990, pp. 1-6.
- [21] M. Katayama and M. Kawato, "Learning trajectory and force control of an artificial muscle arm by parallel-hierarchical neural network model", In R. P. Lippmann, J. E. Moody and D. S. Touretzky (eds.), *Advances in Neural Information Processing Systems 3*, San Mateo, CA, Morgan Kaufmann Publishers, 1991, pp. 436-442.
- [22] M. Katayama and M. Kawato, "A parallel-hierarchical neural network model for motor control of musculo-skeletal system", *System & Computers in Japan*, 22, 1991, pp. 95-105.
- [23] D. Marr, "A theory of cerebellar cortex", *J. Physiol.*, 202, 1969, pp. 437-470.
- [24] J. S. Albus, "A theory of cerebellar functions", *Math. Biosci.*, 10, 1971, pp. 25-61.
- [25] N. Tsukahara and M. Kawato, "Dynamic and plastic properties of the brain stem neuronal networks as the possible neuronal basis of learning and memory", In S. Amari and M. A. Arbib (eds.), *Lecture Notes in Biomathematics 45, Competition and Cooperation in Neural Nets*, Berlin, Springer-Verlag, 1982, pp. 430-441.
- [26] M. Ito, *The Cerebellum and Neural Control*, New York: Raven Press, 1984.
- [27] M. Fujita, "Adaptive filter model of the cerebellum", *Biological Cybernetics*, vol.45, 1982, pp. 195-206.
- [28] Iriki 入来正躬 and 外山敬介, *生理学1*. 1987, 文光堂: 東京.
- [29] C. Ghez and S. Fahn, "The cerebellum", In E. R. Kandel and J. H. Schwartz (eds.), *Section 39 Principles of Neural Science*, New York, Elsevier, 1985, pp. 502-521.
- [30] O. Oscarsson, "Functional organization of olivary projection to the cerebellar anterior lobe", In J. Courville, C. Montigny and Y. Lamarre (eds.), *The Inferior Olivary Nucleus: Anatomy and Physiology*, New York, Raven Press, 1980, pp. 279-289.
- [31] V. B. Brooks and W. T. Thach, "Cerebellar control of posture and movement", In J. M. Brookhart and V. B. Mountcastle (eds.), *Handbook of physiology: SECTION 1 The Nervous System, vol.2 motor control, Part2*, Maryland, American Physiological Society, 1981, pp. 877-946.
- [32] Katayama 片山 and 川人, "速い運動および拘束運動中の仮想軌道と剛性楕円体", 第6-回生体・生理工学シンポジウム, 1991, pp. 337-340.
- [33] [1] M. Katayama and M. Kawato, "Virtual trajectory and stiffness ellipse during multi-joint movement predicted by neural inverse models", *Biological Cybernetics*, 69, 1993, pp. 353-362.
- [34] D. J. Bennet, J. M. Hollerbach, Y. Xu and I. W. Hunter, "Time-varying stiffness of human elbow joint during cyclic voluntary movement", *Experimental Brain Research*, , 1992,
- [35] J. B. MacNeil, R. E. Kearney and I. W. Hunter, "Identification of time-varying biological systems from ensemble data", *IEEE Transactions on Biomedical Engineering*, 39(12), 1992, pp. 1213-1225.
- [36] F. Mussa-Ivaldi and T. Flash, "Neural, mechanical, and geometric factors subserving arm posture in humans", *Journal of Neuroscience*, Vol.5(No.10), 1985, pp. 2732-2743.
- [37] T. Flash and F. Mussa-Ivaldi, "Human arm stiffness characteristics during the maintenance of posture", *Experimental Brain Research*, 82, 1990, pp. 315-326.
- [38] F. Lacquaniti, F. Licata and J. F. Soeching, "The mechanical behavior of the human forearm in response to transient perturbation", *Biological Cybernetics*, 44, 1982, pp. 35-46.
- [39] W. A. Mackay, D. J. Crammond, H. C. Kwan and J. T. Murphy, "Measurements of human forearm viscoelasticity", *Journal of Biomechanics*, Vol.19(No.3), 1986, pp. 231-238.

- [40] N. Hogan, "Impedance control: An approach to manipulation: Part I - Theory, Part II - Implementation, Part III - Applications", *ASME Journal of Dynamic System Measurement and Control*, 107, 1985, pp. 1-24.
- [41] Yamada山田, "筋肉の生理学", In 入来 and 外山 (eds.), *生理学I*, 文光堂, 1987, pp. 65-94.
- [42] Aoki青木, "脊髓反射", In 入来 and 外山 (eds.), *生理学I*, 文光堂, 1987, pp. 482-506.
- [43] P. Rudomin, "Presynaptic inhibition of muscle spindle and tendon organ afferents in the mammalian spinal cord", *Trends in Neurosciences*, Vol. 13(No.12), 1990, pp. 499-505.
- [44] R. B. Stein and C. Capaday, "The modulation of human reflexes during functional motor tasks", *Trends in Neurosciences*, 11(7), 1988, pp. 328-332.
- [45] S. Dubowsky and D. T. DesForges, "The application of model referenced adaptive control to robotic manipulators", *Journal of Dynamic System, Measurement and Control*, 101, 1979, pp. 193-200.
- [46] J. E. Slotine and W. Li, "On the adaptive control of robot manipulators", *International Journal Robotics Research*, 6(3), 1987,
- [47] Arimoto有本, "これからのロボットのモデリング", *日本ロボット学会誌*, 7(2), 1989, pp. 84-88.
- [48] Ikeda池田 and 北村, "ニューラルネットワークによる倒立振り子安定化の学習制御", 第31回自動制御連合講演会, 1988, pp. 257-258.
- [49] A. Guez and J. Selinsky, "A neuromorphic controller with a human teacher", *Proc. International Conference on Neural Network*, 2, 1988, pp. 595-602.
- [50] V. V. Tolat and B. Widrow, "An adaptive "Broom Balancer" with visual input", *Proc. International Conference on Neural Networks*, 2, 1988, pp. 641-647.
- [51] A. G. Barto, "Connectionist learning for control", In T. Miller, R. S. Sutton and P. J. Werbos (eds.), *Neural Networks for Control*, MA: The MIT Press, 1989, pp. 5-58.
- [52] A. G. Barto, R. S. Sutton and C. W. Anderson, "Neuronlike adaptive elements that can solve difficult learning control problems", *IEEE Transaction on System Man and Cybernetics*, 13, 1983, pp. 834-846.
- [53] M. Kuperstein and J. Rubinstein, "Implementation of an adaptive neural controller for sensory-motor coordination", *IEEE Control Systems Magazine*, 8(2), 1989, pp. 25-30.
- [54] T. M. Martinets, H. J. Ritter and K. J. Schulten, "Three-dimensional neural net for learning visuomotor coordination of a robot arm", *IEEE Transactions on Neural Networks*, 1(1), 1990, pp. 131-136.
- [55] W. T. Miller III, R. P. Hewes, F. H. Glanz and L. G. Kraft III, "Real-time dynamic control of an industrial manipulator using a neural-network-based learning controller", *IEEE Transactions on Robotics & Automation*, 6(1), 1990, pp. 1-9.
- [56] D. Psaltis, A. Sideris and A. Yamamura, "Neural controllers", *Proc. IEEE Int. Conf. Neural Networks*, 4, 1987, pp. 551-557.
- [57] M. I. Jordan, "Supervised learning and systems with excess degrees of freedom", Univ. Massachusetts at Amherst, 88-27, 1988.
- [58] K. S. Narendra and K. Parthasarathy, "Identification and control of dynamical systems using neural networks", *IEEE Transactions on Neural Networks*, 1(1), 1990, pp. 4-27.
- [59] J. S. Albus, "A new approach to manipulator control: The cerebellar model articulation

- controller (CMAC)", *Transactions of American Society of Mechanical Engineering*, 97, 1975, pp. 220-227.
- [60] C. G. Atkeson and D. J. Reinkensmeyer, "Using associative content-addressable memories to control robots", *Proc. IEEE Conference on Decision and Control*, 1988, pp. 792-797.
- [61] C. Stanfill and D. Waltz, "Toward memory-based reasoning", *Communications of the Association for Computing Machinery*, 29(12), 1986, pp. 1213-1228.
- [62] T. Poggio and F. Girosi, "Extensions of a theory of networks for approximation and learning: dimensionality reduction and clustering", MIT A.I. Memo, 1167, 1990.
- [63] B. Irie and S. Miyake, "Capabilities of three-layered perceptrons", *Proc. International Conference on Neural Networks*, 1, 1988, pp. 641-648.
- [64] K. Funahashi, "On the approximate realization of continuous mapping by neural network", *Neural Networks*, 2, 1989, pp. 183-192.
- [65] R. M. Sanner and J. J. E. Slotine, "Gaussian networks for direct adaptive control", *IEEE Transactions on Neural Networks*, 3(6), 1992, pp. 837-863.
- [66] M. H. Raibert and J. J. Craig, "Hybrid position/force control of manipulators", In M. Brady, J. M. Hollerbach, T. L. Johnson, T. Lozano-Perez and M. T. Mason (eds.), *Robot Motion*, MA, MIT Press, 1982, pp.
- [67] Kawasaki川崎, "オンラインパラメータ同定によるマニピュレータの軌道制御", *計測自動制御学会論文集*, 20(9), 1984, pp. 8-15.
- [68] P. K. Khosla and T. Kanade, "Parameter identification of robot dynamics", *Proc. IEEE Conf. Decision and Control*, 1985, pp. 1754-1760.
- [69] Osuka大須賀, "非線形メカニカルシステムの適応制御", *計測自動制御学会論文集*, 22(7), 1986, pp. 756-762.
- [70] J. J. Craig, P. Hsu and S. S. Sastry, "Adaptive control of mechanical manipulators", *IEEE Int. Conf. on Robotics and Automation*, 1986, pp. 190-195.
- [71] Ogura小倉久直, *確率過程論*, 東京: コロナ社, 1978.
- [72] N. Hogan, "Stable execution of contact task using impedance control", *Proceeding IEEE Int. Conf. Robotics & Automation*, 1987, pp. 1047-1054.
- [73] M. Kawato, "The feedback-error-learning neural network for supervised motor learning", In R. Eckmiller (eds.), *Advanced neural computers.*, Amsterdam, Elsevier, 1990, pp. 365-372.
- [74] J. J. E. Slotine and W. Li, *Applied Nonlinear Control*, New Jersey: Prentice-Hall, 1991.
- [75] D. Whitney, "Force feedback control of manipulator fine motions", *Journal of Dynamic Systems, Measurement and Control*, , 1977, pp. 91-97.
- [76] J. K. Salisbury, "Active stiffness control of a manipulator in cartesian coordinates", *Proc. IEEE Int. Conf. on Decision and Control*, 1980,
- [77] Tachi館ら, "力センサを用いないダイレクトドライブマニピュレータのインピーダンス制御", *日本ロボット学会誌*, 7(3), 1989, pp. 1-13.
- [78] Tachi館 and 榊, "インピーダンス制御マスタ・スレーブ・システムI,II", *日本ロボット学会誌*, 8(3), 1990, pp. 1-24.
- [79] T. Hirano, "Differential pre- and postsynaptic mechanisms for synaptic potentiation and depression between a granule cell and purkinje cell in rat cerebellar culture", *SYNAPSE*, 7,

- 1991, pp. 321-323.
- [80] D. J. Linden, M. H. Dickinson, M. Smeyne and J. A. Connor, "A long-term depression of AMPA currents in cultured cerebellar purkinje neurons", *Neuron*, 7, 1991, pp. 81-89.
- [81] G. Andersson and O. Oscarsson, "Projections to lateral vestibular nucleus from cerebellar climbing fiber zones", *Experimental Brain Research*, 32, 1978, pp. 549-564.
- [82] G. Andersson and O. Oscarsson, "Climbing fiber microzones in cerebellar vermis and their projection to different groups of cells in the lateral vestibular nucleus", *Experimental Brain Research*, 32, 1978, pp. 565-579.
- [83] P. F. C. Gilbert and W. T. Thach, "Purkinje cell activity during motor learning", *Brain Research*, 128, 1977, pp. 309-328.
- [84] T. J. Carew, "Posture and locomotion", In E. R. Kandel and J. H. Schwartz (eds.), *Section 37 Principles of Neural Science*, New York, Elsevier, 1985, pp. 478-486.
- [85] M. Udo, K. Matsukawa, H. Kamei, K. Minoda and Y. Oda, "Cerebellar control of locomotion: effects of cooling cerebellar intermediate cortex in high decerebrate and awake walking cats", *J. Neurophysiology*, vol.44(No.1), 1980, pp. 119-133.
- [86] S. Nagao, "Effects of vestibulocerebellar lesions upon dynamic characteristics and adaptation of vestibulo-ocular and optokinetic responses in pigmented rabbits", *Experimental Brain Research*, 53, 1983, pp. 36-46.
- [87] L. S. Stone and S. G. Lisberger, "Visual responses of Purkinje cells in the cerebellar flocculus during smooth pursuit eye movements in monkeys. I. Simple spikes", *Journal of Neurophysiology*, 63, 1990, pp. 1241-1261.
- [88] R. F. Thompson, "The neurobiology of learning and memory", *Science*, 233, 1986, pp. 941-947.
- [89] M. Ito, "Neurophysiological aspects of the cerebellar motor control system", *International Journal of Neurology*, 7, 1970, pp. 162-176.
- [90] M. Fujita, "Simulation of adaptive modification of the vestibulo-ocular reflex with an adaptive filter model of the cerebellum", *Biological Cybernetics*, 45, 1982, pp. 207-214.
- [91] G. I. Allen and N. Tsukahara, "Cerebrocerebellar communication systems", *Physiological Review*, Vol. 54(No.4), 1974, pp. 957-1006.
- [92] J. C. Houk and A. G. Barto, "Distributed sensorimotor learning", In G. E. Stelmach and R. J. (eds.), *Tutorial in motor behavior II*, Amsterdam, Elsevier, 1991, pp.
- [93] R. C. Miall, J. F. Stein and D. J. Weir, "The cerebellum as an adaptive smith predictor in visuomotor control", *Society of Neuroscience Abstracts*, 15, 17.11, 1989,
- [94] J. I. Simpson and K. E. Alley, "Visual climbing fiber input to rabbit vestibulo-cerebellum: a source of direction-specific information", *Brain Res.*, 82, 1974, pp. 302-308.
- [95] K. Matsukawa, H. Kamei, K. Minoda and M. Udo, "Interlimb coordination in cat locomotion investigated with perturbation I. Behavioral and electromyographic study on symmetric limbs of decerebrate and awake walking cats", *Exp. Brain Res.*, 46, 1982, pp. 425-437.
- [96] K. Maekawa and J. I. Simpson, "Climbing fiber responses evoked in vestibulocerebellum of rabbit from visual system", *J. Neurophysiol.*, 36, 1973, pp. 649-666.
- [97] S. Nagao, "Role of cerebellar flocculus in adaptive interaction between optokinetic eye movement response and vestibulo-ocular reflex in pigmented rabbits", *Experimental Brain Research*, 77, 1989, pp. 541-551.
- [98] Nagao永雄, "小脳による運動の学習制御機構", *医学のあゆみ*, 145(5), 1988, pp. 362-366.

- [99] K. Ezure and W. Graf, "A quantitative analysis of the spatial organization of the vestibulo-ocular reflexes in lateral- and frontal-eyed animals. I. Orientation of semicircular canals and extraocular muscles", *Neuroscience*, 12(1), 1984, pp. 85-93.
- [100] A. J. Pellionisz and W. Graf, "Tensor network model of the three-neuron vestibulo-ocular reflex-arc in cat", *J. Theor. Neurobiol.*, 5, 1987, pp. 127-151.
- [101] J. I. Simpson, W. Graf and C. S. Leonard, "Three-dimensional representation of retinal image movement by climbing fiber activity", In P. Strata (eds.), *Experimental Brain Research Series: 17 The Olivocerebellar System in Motor Control*, Berlin, Springer-verlag, 1989, pp. 323-337.
- [102] D. A. Robinson, "Control of eye movements", In J.M. Brookhart and V.B. Mountcastle (eds.), *HANDBOOK OF PHYSIOLOGY: SECTION 1 The Nervous System, vol.2 motor control, Part2*, Maryland, American Physiological Society, 1981, pp. 1275-1320.
- [103] Takanishi高西, "2足歩行ロボットの動歩行に関する研究", 早稲田大学, 1988.
- [104] L. M. Schick and G. N. Orlovsky, "Neurophysiology of locomotor automatism", *Physiological Reviews*, 56, 1976, pp. 465-501.
- [105] M. Udo, H. Kamei, K. Matsukawa and K. Tanaka, "Interlimb coordination in cat locomotion investigated with perturbation II. Correlates in neuronal activity of Deiters' cells of decerebrate walking cats", *Experimental Brain Research*, 46, 1982, pp. 438-447.
- [106] Tanaka田中, "視覚による姿勢制御", In 入来 and 外山 (eds.), *生理学1*, 文光堂, 1987, pp. 516.
- [107] L. M. Nashner, "Adapting reflexes controlling the human posture", *Experimental Brain Research*, 26, 1976, pp. 59-72.
- [108] M. Udo, K. Matsukawa, H. Kamei and Y. Oda, "Simple and complex spike activities of purkinje cells during locomotion in the cerebellar vermal zones of decerebrate cats", *Exp. Brain Res.*, 41, 1981, pp. 292-300.
- [109] H. Frossberg, S. Grillner and S. Rossignol, "Phasic gain control of reflexes from the dorsum of the paw during spinal locomotion", *Brain Res.*, 132, 1977, pp. 121-139.
- [110] Mori森茂美, "歩行運動の生理学", In 入来 and 外山敬介 (eds.), *生理学1*, 文光堂, 1987, pp. 520-536.
- [111] Udo有動正夫, "小脳", In 入来 and 外山敬介 (eds.), *生理学1*, 文光堂, 1987, pp. 601-619.
- [112] R. Gellman, J. C. Houk and A. R. Gibson, "Somatosensory properties of the inferior olive of the cat", *J. Comparative Neurology*, 215, 1983, pp. 228-243.
- [113] M. Ito, "Long-term depression", *Annual Review of Neuroscience*, 12, 1989, pp. 85-102.
- [114] S. Nagao, "Behavior of floccular purkinje cells correlated with adaptation of vestibulo-ocular reflex in pigmented rabbits", *Experimental Brain Research*, 77, 1989, pp. 531-540.
- [115] Kawano河野, 山根, 渡辺 and F. A. Miles, "追従眼球運動とその神経機序", 電子技術総合研究所, 52-9, 1988.
- [116] K. Kawano, M. Shidara and S. Yamane, "Neural activity in dorsolateral pontine nucleus of alert monkey during ocular following response", *Journal of Neurophysiology*, 67, 1992, pp. 680-703.
- [117] M. Shidara and K. Kawano, "Role of purkinje cells in the ventral paraflocculus in short-latency ocular following responses", *Experimental Brain Research*, 93, 1993, pp. 185-195.
- [118] D. A. Robinson, "Oculomotor unit behavior in the monkey", *Journal of Neurophysiology*,

- 33, 1970, pp. 393-404.
- [119] E. L. Keller, "Accommodative vergence in the alert monkey motor unit analysis", *Vision Research*, 13, 1973, pp. 1565-1575.
- [120] N. E. Berthier, A. G. Barto and J. E. Moore, "Linear systems analysis of the relationship between firing of deep cerebellar neurons and the classically conditioned nictitating membrane in rabbits", *Biological Cybernetics*, 65, 1991, pp. 99-105.
- [121] R. A. Jacobs, M. I. Jordan and A. G. Barto, "Task decomposition through competition in a modular connectionist architecture: The what and where vision tasks", COINS Technical Report, 90-27, 1990.
- [122] R. A. Jacobs and M. I. Jordan, "A competitive modular connectionist architecture", In R. P. Lippmann, J. E. Moody and D. S. Touretzky (eds.), *Advances in Neural Information Processing Systems 3*, San Mateo, CA, Morgan Kaufmann Publishers, 1991, pp. 767-773.
- [123] S. J. Nowlan, "Competing experts: An experimental investigation of associative mixture models", Univ. Toronto Tech. Rep., CRG-TR-90-5, 1990.
- [124] S. J. Nowlan and G. E. Hinton, "Evaluation of adaptive mixtures of competing experts", In R. P. Lippmann, J. E. Moody and D. S. Touretzky (eds.), *Advances in Neural Information Processing Systems 3*, San Mateo, CA, Morgan Kaufmann Publishers, 1991, pp. 774-780.
- [125] P. K. Allen, *Robotic object recognition using vision and touch.*, Kluwer Academic Publishers, 1987.
- [126] A. Pentland and R. Bolles, "Learning and recognition in natural environment", In M. Brady (eds.), *Robotics Science*, MA, MIT Press, 1989, pp. 164-207.
- [127] S. Sastry and M. Bodson, *Prentice Hall Information and System Science Series, Adaptive Control*, NJ: Prentice Hall, 1989.
- [128] S. Geman, "Some averaging and stability results for random differential equations", *SIAM Journal of Applied Mathematics*, 36(1), 1979, pp. 86-105.
- [129] Ito伊藤, 確率論, 東京: 岩波書店, 1953.
- [130] J. J. Wang, J. Kim H. and T. J. Ebner, "Climbing fiber afferent modulation during a visually guided, multi-joint arm movement in the monkey", *Brain Research*, 410, 1987, pp. 323-329.
- [131] F. A. Miles, D. J. Braitman and B. M. Dow, "Long-term adaptive changes in primate vestibuloocular reflex. IV. Electrophysiological observations in flocculus of adapted monkeys", *Journal of Neurophysiology*, 43(5), 1980, pp. 1477-1493.
- [132] S. G. Lisberger, "The neural basis for learning of simple motor skills", *Science*, 242, 1988, pp. 728-735.
- [133] R. Llinas, K. Walton and D. E. Hillman, "Inferior olive: Its role in motor learning", *Science*, 190, 1975, pp. 1230-1231.
- [134] A. J. Pellionisz and R. Llinas, "Tensorial approach to the geometry of brain function: cerebellar coordination via a metric tensor", *Neuroscience*, 5, 1980, pp. 1125-1136.
- [135] T. J. Anastasio and D. A. Robinson, "The distributed representation of vestibulo-oculomotor signals by brain-stem neurons", *Biological Cybernetics*, 61, 1989, pp. 79-88.
- [136] T. J. Anastasio and D. A. Robinson, "Distributed parallel processing in the vertical vestibulo-ocular reflex: learning networks compared to tensor theory", *Biological Cybernetics*, 63, 1989, pp. 161-167.
- [137] T. J. Anastasio, "Neural network models of velocity storage in the horizontal vestibulo-ocular

- reflex", *Biological Cybernetics*, 64, 1991, pp. 187-196.
- [138] F. A. Miles, J. H. Fuller, D. J. Braitman and B. M. Dow, "Long-term adaptive changes in primate vestibuloocular reflex. III. Electrophysiological observations in flocculus of normal monkeys", *Journal of Neurophysiology*, 43(5), 1980, pp. 1437-1476.
- [139] M. I. Jordan, "Motor learning and the degrees of freedom problem", In M. Jeannerod (eds.), *ATTENTION and PERFORMANCE XIII Motor Representation and Control*, Hillsdale, NJ, Lawrence Erlbaum Associates, 1990, pp. 796-836.

本論文に関する発表論文等

2章

- ・五味, & 川人 (1992). 人腕多関節運動中のステイフネスの計測. 電子通信情報学会技術報告, Vol.91 No.530, NC91-145, 99-106.
- ・Gomi, H., & Kawato, M. (1992). Human hand stiffness during discrete point-to-point multi-joint movement. In Proceeding of the 14th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 4 (pp. 1628-1629). Paris.
- ・Kawato, M., Katayama, M., Gomi, H., & Koike, Y. (1992). Virtual trajectory and stiffness ellipse during multi-joint arm movement. In Neural Networks for Computing, 1. Snowbird, Utah.

3章

- ・五味, & 川人 (1990). フィードバック誤差学習による不安定システムの閉ループ学習制御. 電子通信情報学会技術報告, Vol.89 No.463, NC89-62, 7-12.
- ・五味, & 川人 (1990). フィードバック誤差学習による閉ループシステムに対する学習制御. In 電気学会 第2回シンポジウム電磁力関連のダイナミクス講演論文集, (pp. 235-240). 名古屋.
- ・五味, & 川人 (1990). 神経回路モデルを用いた学習型インピーダンス制御. In 第8回日本ロボット学会学術講演会予稿集, No.1 (pp. 17-20). 仙台.
- ・五味, & 川人 (1990). 対象物操作のための運動学習制御. 電子通信情報学会技術報告, Vol.90 No.173, NC90-19, 45-52.
- ・Gomi, H., & Kawato, M. (1990). Learning control for a closed loop system using feedback-error-learning. In Proceeding of the 29th IEEE Conference on Decision and Control, (pp. 3289-3294). Hawaii.
- ・五味, & 川人 (1991). フィードバック誤差学習による閉ループシステムの学習制御. システム制御情報学会論文誌, 4(1), 37-47.
- ・Gomi, H., & Kawato, M. (1993). Neural network control for a closed-loop system using feedback-error-learning. Neural Networks, 6(7), 933-946.

4章

- ・五味, & 川人 (1990). 小脳における姿勢制御学習系のモデル化. In 神経回路学会平成2年全国大会講演論文集, (pp. 57). 東京.
- ・川人, & 五味 (1990). 小脳各部位の計算論的モデル-フィードバック誤差学習による統一的理解-. In 計測自動制御学会 第5回生体生理工学シンポジウム, (pp. 169-172). 九州.
- ・五味, & 川人 (1991). 小脳各部位における学習系の計算論的モデル. 電子通信情報学会技術報告, Vol.90 No.483, NC90-97, 173-178.
- ・五味, & 川人 (1991). 前庭動眼反射・視機性眼球運動適応系の計算モデル. In 第30回計測自動制御学会学術講演会予稿集, (pp. 829-830). 山形.
- ・Kawato, M., & Gomi, H. (1991). Model of Four Regions of the Cerebellum. In Proceedings

- of the IEEE International Joint Conference on Neural Networks, (pp. 410-419). Singapore.
- ・五味, & 川人 (1992). 小脳における運動学習適応系モデル—計算論と生理学—. 応用物理, 61(10), 1035-1038.
 - ・Gomi, H., & Kawato, M. (1992). Adaptive feedback control models of the vestibulocerebellum and spinocerebellum. *Biological Cybernetics*, 68/2, 105-114.
 - ・Kawato, M., & Gomi, H. (1992). The cerebellum and VOR/OKR Learning Models. *Trands in Neuro Science*, 15(11), 445-453.
 - ・Kawato, M., & Gomi, H. (1992). A computational model of four regions of the cerebellum based on feedback-error learning. *Biological Cybernetics*, 68/2, 95-103.
 - ・Kawato, M., & Gomi, H. (1992). Feedback-error-learning model of cerebellar motor control. In VIIIth TMIN International Symposium -Role of the Cerebellum and Basal Ganglia in Voluntary Movement-, (pp. 53). Tokyo.
 - ・Kawato, M., & Gomi, H. (1993). Feedback-error-learning model of cerebellar motor control. In N. Mano, I. Hamada, & M. R. DeLong (Eds.), VIIIth TMIN International Symposium -Role of the Cerebellum and Basal Ganglia in Voluntary Movement- (pp. 51-61). B.V.: Elsevier Scieince Publishers.

5 章

- ・ Shidara, M., Kawano, K., Gomi, H., & Kawato, M. (1992). Linear regression analysis of relationship between simple spike activity of purkije cells in the ventral paraflocculus of alert monkey and ocular following response. In VIIIth TMIN International Symposium -Role of the Cerebellum and Basal Ganglia in Voluntary Movement-, (pp. 70). Tokyo.
- ・五味, 設楽, 河野, & 川人 (1993). 逆ダイナミクス表現によるサル小脳傍片葉プルキンエ細胞発火パターンの再構成. 電子通信情報学会技術報告, Vol.92 No.521, NC92-126, 245-252.
- ・ Gomi, H., Shidara, M., Kawano, K., & Kawato, M. (1993). Reconstruction of temporal firing patterns of purkinje-cells in monkey ventral paraflocculus based on inverse dynamics representation. In *Neural Networks for Computing*, . Snowbird, Utah.
- ・ Shidara, M., Kawano, K., Gomi, H., & Kawato, M. (1993). Inverse dynamics model eye movement control by Purkinje cells in the cerebellum. *Nature*, 365(2), 50-52.

6 章

- ・ Gomi, H., & Kawato, M. (1992). Recognition of manipulated objects by motor learning. In J. E. Moody, S. J. Hanson, & R. P. Lippmann (Eds.), *Advances in Neural Information Processign Systems 4*. (pp. 547-554). San Mateo, CA: Morgan Kaufmann Publishers.
- ・五味, & 川人 (1992). 運動学習による操作対象物の認識と制御のための内部表現の獲得. In 第31回計測自動制御学会学術講演会予稿集, (pp. 813-814). 熊本.
- ・ Gomi, H., & Kawato, M. (1993). Recognition of manipulated objects by motor learning with modular architecture networks. *Neural Networks*, 6(4), 485-497.
- ・ Gomi, H., & Kawato, M. (1993). Modular neural network for recognition of manipulated objects. In *Proceedings of the 1993 IEEE/Nagoya University WWW On Learning and Adaptive System*, (pp. 77-84). Nagoya, Japan.