

# I-21 データマイニングを目指したセンサと構造物の データモデルの統合化に関する研究

## Integration of Sensor and Structural Data Models toward Data Mining

吉田善博<sup>1</sup>・矢吹信喜<sup>2</sup>

Yoshihiro Yoshida, Nobuyoshi Yabuki

**抄録:** センサの無線化, 小型化, 低価格化に伴い, 将来, 構造物の健全度モニタリングのために相当数のセンサが数多くの構造物に設置されるようになると予想される. 本研究では, こうした膨大な量のセンサデータから有意な知識を発見するために, まず, リレーショナルデータモデルのスタースキーマを用いてセンサデータモデルを開発した. 次に, このセンサデータモデルと構造物に関するデータを表現するプロダクトモデルを統合化した統合データモデルを開発した. さらに, 2層のラーメン構造の実験用モデルを作成して振動台実験を行い, 統合データモデルに基づくデータベースに格納して, データモデルの検証を行った. 最後に, 格納されたデータを用いてデータマイニングを実施した. スタースキーマ型の統合データモデルはデータマイニングに適しており, センサデータから構造の変化を確認することが可能であることが明らかとなった.

**Abstract:** In order to discover useful knowledge from a large amount of data observed by many sensors to be installed on structures in the near future, first, a sensor data model was developed, based on the star schema of the relational data model. Then, the sensor data model was merged with a product data model representing structural frame models. Three types of two-story experimental frame models were made and a series of shake table tests were executed. The experimental data were stored in accordance with the developed data model and data mining was performed for knowledge discovery.

**キーワード:** センサデータモデル, プロダクトモデル, データマイニング, 関係データベース, スタースキーマ

**Keywords:** Sensor data model, Product model, Data mining, Relational data model, Star schema

### 1. はじめに

戦後, 我が国では膨大な量の建物や社会基盤の建設を行っており, これから10年から20年後には大量の構造物が更新時期を迎えるが, 逼迫した財政下では, 適切な維持管理によりなるべく長寿命化を図る必要がある. そのためには, 構造物の点検とセンサ類によるモニタリングが重要と考えられる.

今後センサやセンサネットワークが小型化し低価格になるに従い, 相当数のセンサが数多くの構造物に設置されるようになると予想される. こうした膨大な量のセンサデータがコンピュータに蓄えられるようになると, 構造物の管理者は, データから何らかの意味のある推論や結論を導き出そうとするであろう. しかし, あまりにも膨大なデータ量のため, 結局初めから予想している結果に合致しそうなデータを集めて結論付けてしまう, あるいは, 予想しなかった重大な健全度に関する診断が導き出せるデータの関係等をみすみす見逃してしまうといったことが起こると懸念される. これでは, せっかく数多くのセンサを設置しても無駄に

なる可能性がある.

構造物の膨大なセンサデータから有意な知識を発見するためには, 単なるデータマイニングのようなデータの比較だけではあまりうまくいかず, センサが設置されている構造物の部材の幾何情報, 境界条件, 材料等の属性情報, および部材間関係などのコンテキストの情報, さらに構造力学に関する定性的な知識を加味した知識発見に関する新しい方法論を確立する必要があると考えられる.

大量のセンサデータをシステムティックに貯蔵するためのデータモデルについては, 米国においては Peng, Law<sup>1),2)</sup>によって NEES (George E. Brown, Jr. Network for Earthquake Engineering Simulation) のために NEES Reference Data Model が開発された. 我が国では矢吹<sup>3),4)</sup>が, 独立行政法人防災科学技術研究所の E-Defense のために, イベントに基づくスタースキーマ<sup>5)</sup>を利用して EDgrid データモデル<sup>3),4)</sup>の開発を行った. 一方, 構造物の3次元モデル, 部材等の属性や関係を表現するプロダクトモデルについては国際標準として ISO10303 の STEP (STandard for the Exchange of Product

1 : 学生会員 工修 大阪大学大学院工学研究科 環境・エネルギー工学専攻 博士後期課程 環境設計情報学領域  
2 : 正会員 Ph.D. 大阪大学大学院工学研究科 環境・エネルギー工学専攻 教授  
(〒565-0871 大阪府吹田市山田丘 2-1, Tel :06-6879-7660, E-mail : yabuki@see.eng.osaka-u.ac.jp)

model data) <sup>6)</sup>, 建築の業界標準としては, IAI (International Alliance for Interoperability) の IFC<sup>7)</sup> (Industry Foundation Classes) 等がある. しかし, センサデータを管理するためのデータモデルの開発と構造物の形状データや属性情報等を管理するためのデータモデルの開発は別々に行われているのが現状である.

そこで本研究では, センサデータから知識発見を図るため, まず, 前述の EDgrid のデータモデルに基づいて一般的なセンサデータモデルを開発した. 次に, データマイニング等によって有意な知識を発見することができるように, センサに関するデータとセンサが配置されている部材に関するデータが密接に関係しあったデータモデルの構築を目的として, プロダクトモデルと本研究で開発したセンサデータモデルを統合化した統合モデルの開発を行った. 最後に, 2 層のラーメン構造モデルの振動台実験データを統合モデルに従ってデータベースに格納して, データモデルの検証とデータマイニングへの適用性検討を行った.

## 2. センサデータモデルの開発

センサデータモデルの開発に当たっては, EDgrid で開発されたデータモデルが柔軟性・拡張性に優れた汎用的なデータモデルであったことから, EDgrid と同様にスタースキーマの設計手法を用いて行うこととした. スタースキーマとは, 一つのテーブルといくつかの次元テーブルの集合で構築され, 全ての次元テーブルはイベントテーブルとのみ関係している. そのためイベントテーブルを中心とする星形となる. この手法を用いることによって, テーブル間のリレーションシップを最小限に抑えることができ, 柔軟性・拡張性に優れたデータモデルを作成することが可能である. 従って, データマイニングに適していると考えられている <sup>5)</sup>.

本研究で開発したセンサデータモデルを図-1 に示す. 図-1 中で, Primary Key は主キーを表し, Foreign Key は外部キーを表す. 主キーは, データベース中のレコードを一意に識別するために設定される項目である. 一方, 外部キーは, 他のテーブルの主キーを参照するために設定される項目である. 図-1 に示すセンサデータモデルは, EDgrid と同様にデータモデルの中心に Event テーブルを配置し, その周りにセンサに関するデータを格納するために必要なテーブルを配置した. センサデータモデルについて以下に記す.

- ・ センサに関するデータ (センサ名, メーカー等) は, Equipment テーブルに格納する.
- ・ センサの設定に関するデータは, Setting テーブルと Value テーブルに格納する.
- ・ センサの設定データは, Setting テーブルと Value テーブルを Event テーブルでリンクさせることに

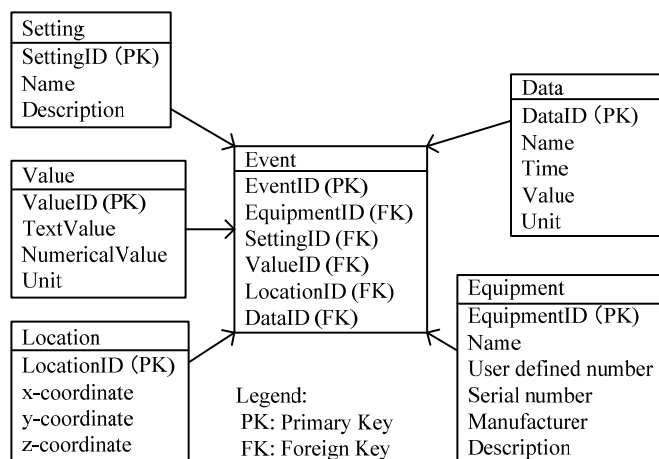


図-1 センサデータモデル

よって表現する. 従って, センサのサンプリングレートに関するデータを格納する場合は, Setting テーブルの「Name」に「サンプリングレート」を格納し, Value テーブルの「Numerical Value」に値を格納することとなる.

- ・ センサの位置に関するデータは, X, Y, Z 座標を Location テーブルに格納する.
- ・ 計測データそのものは, テキストファイルなどに記録されており, そのファイルのメタデータは Data テーブルに格納される.

## 3. センサ及びプロダクトモデルの統合化

### (1) 統合化の目的

構造物の膨大なセンサデータから有意な知識を自動的あるいは半自動的に発見するためには, センサ情報だけでは足りず, 配置されている周辺環境のコンテキストが必要だと考えられる. すなわち, センサに関するデータとセンサが配置されている部材に関するデータが密接に関係しあったデータモデルが必要である. そこで本研究では, IFC のプロダクトモデルと EDgrid のデータモデルをベースとして開発したセンサデータモデルの 2 つのデータモデルを用いてデータモデルの統合を行うこととした.

プロダクトモデルは, オブジェクト指向の概念に基づいたデータモデルであるのに対し, センサデータモデルはリレーショナルデータモデルの概念に基づいて開発されたデータモデルである. 従って, 両モデルを統合するためには, 概念の統一を図る必要がある. 本研究ではリレーショナルデータモデルの概念に従ってデータモデルの統合を行うこととした. なぜなら, オブジェクトデータモデルよりもリレーショナルデータモデルの方がデータマイニングとの親和性が高く, リレーショナルデータモデルのテーブル同士の関連付け

によってセンサとセンサが取り付けられている部材の関連付けを行うことが可能であるからである。しかし、オブジェクトデータモデルからリレーショナルデータモデルに変換することが可能であることは一般に知られている<sup>5)</sup>。

## (2) プロダクトモデルの開発とセンサデータモデルの統合

プロダクトモデルとしては、IFCのような膨大なデータモデルがあるが、本研究ではセンサデータモデルとの統合による検討を目的としているため、骨組構造を対象とした簡単なプロダクトモデルを開発することとした。ただし、IFCとの親和性を持つようにした。センサデータモデルと同様にデータモデルの中心にEventテーブルを配置して、**図-2**に示すような簡単なプロダクトデータモデルを開発した。各テーブルについて以下に記す。

- ・ 構造物の ID や部材種に関するデータは、StructuralElement テーブルに格納する。
- ・ 部材の形状に関するデータは、CrossSection テーブルと Coordinate テーブルに格納する。
- ・ 部材の形状データは、CrossSection テーブルと Coordinate テーブルを Event テーブルでリンクさせることによって表現する。従って、部材の形状データは、断面形状と部材の長さを CrossSection テーブルに格納し、断面を構成する各点の座標を Coordinate テーブルに格納する。
- ・ 部材の特性（単位重量、弾性係数等）に関するデータについては、Property テーブルと Value テーブルを使用する。
- ・ 部材の特性は、Property テーブルと Value テーブルを Event テーブルでリンクさせることによって表現する。従って、部材の単位重量であれば、Property テーブルの「Name」に「単位重量」を格納し、Value テーブルの「Numerical Value」に値を格納することとなる。

プロダクトモデルのデータを格納するためのテーブルの検討終了後、**図-1**のデータモデルに**図-2**の各テーブルを追加して、センサデータモデルとプロダクトモデルを統合化し**図-3**に示すデータモデルを開発した。**図-3**のデータモデルでは、モデル中央に配置した Event テーブルによって周囲のテーブルを関連付けることにより、部材の形状データや属性情報を表現する。従って、例えば部材の形状データをデータベースに登録する場合には、部材の情報のための StructuralElement テーブルと形状データのための Coordinate テーブルを Event テーブルによって関連付けることによって行う(**図-4**)。このように、スタースキーマでは、テーブル同士の関連付けは全てイベントテーブルを介して行われるので、テーブル同士の

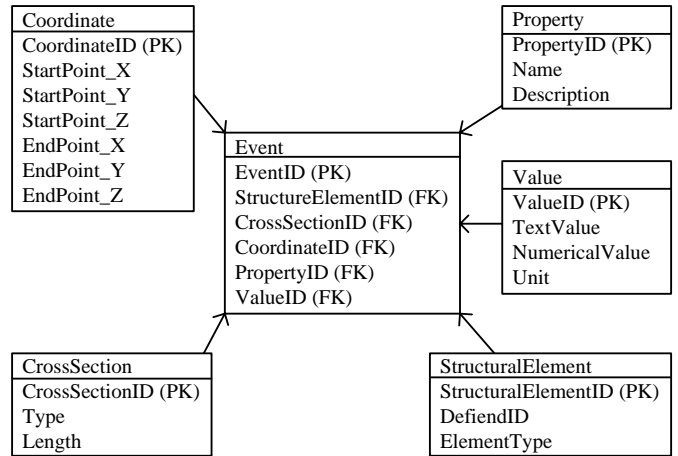


図-2 プロダクトモデルのデータ用のテーブル

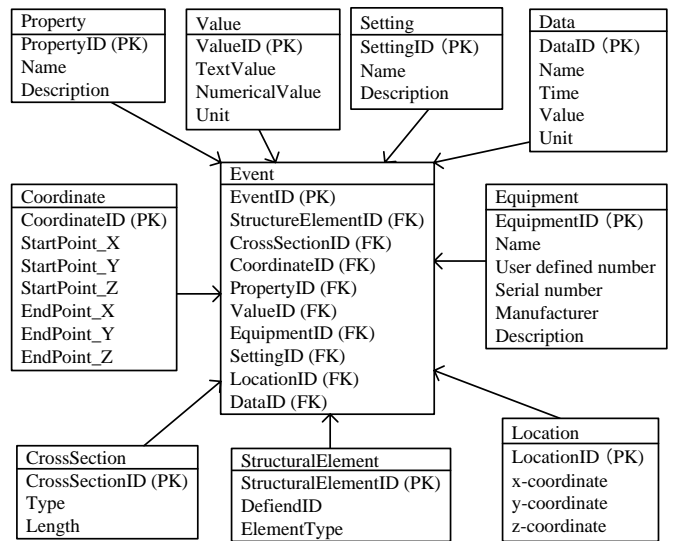


図-3 センサ及びプロダクトモデルを統合化したデータモデル

関係が単純でわかりやすいという特徴がある。データモデルの実装にはMySQL<sup>8)</sup>を使用した。

## (3) コンバートプログラムの作成

3D CAD を用いて設計された骨組構造のデータは、ifcXML<sup>9)</sup>で記述された IFC データとして変換することができる。これをインスタンスファイルと呼ぶ。ifcXML とは、IFC のデータを XML で表現できるようにした言語である。本研究では自動的に ifcXML 形式のインスタンスファイルを**図-3**のデータモデルに従った MySQL のデータベースに登録するプログラムを Visual Basic を用いて作成した。

**図-3**のデータモデルでは Event テーブル周囲に配置した各テーブル間の関係を表現するために、Event テーブルにてテーブルの関連付けを行う必要がある。本研究で開発したコンバートプログラムでは、インスタンスファイルからのデータの取り込みの際に、Event テーブル周囲に配置したテーブルの関連付けの作業も自動で行うことが可能である。

StructuralElement			Coordinate						
StructuralElementID(PK)	DefinedID	Element Type	CoordinateID(PK)	StartPoint X	StartPoint Y	StartPoint Z	EndPoint X	EndPoint Y	EndPoint Z
101	1	Beam	201	0	0	0	1000	0	0
102	2	Slab	202	0	0	0	0	1000	0
103	3	Wall	203	0	0	0	0	0	1000

Event									
EventID(PK)	StructuralElementID(FK)	CrossSectionID(FK)	CoordinateID(FK)	PropertyID(FK)	ValueID(FK)	EquipmentID(FK)	SettingID(FK)	LocationID(FK)	DataID(FK)
11	101	null	201	null	null	null	null	null	null
12	101	null	202	null	null	null	null	null	null
13	101	null	203	null	null	null	null	null	null

図-4 Event テーブルによる関連付けの例

## 4. 無線センサネットワークを使った振動台実験

### (1) 実験用モデルと無線センサネットワーク

本研究で開発した統合モデルによって、センサデータとセンサが設置されている部材の関係が表現可能なことを検証するために、2層のラーメン構造の実験用モデルを用いて簡単な振動台実験を実施した。実験用モデルの設計図を図-5に示す。スラブに木材、柱にアルミ板を使用し、それぞれをL字型の金具によってボルトナットとネジを使って接続した。実験用モデル作成後は、ifcXML形式でインスタンスファイルを作成した。インスタンスファイルの作成には、図-6の灰色で示したクラスを使用した。木材のスラブには、IfcBuildingElementのサブクラスであるIfcSlabを使用し、アルミ板の柱にはIfcColumnを使用した。また、木材とアルミ板の部材長及び座標値には、IfcRepresentationMapを使用した。本研究で開発したデータモデルのテーブルとIFCのクラスのことを表-1に示す。

計測を行うための装置には、米国 Crossbow 社の無線センサネットワークシステムの Imote2<sup>10)</sup>を用いた。Imote2の無線規格は、IEEE 802.15.4の2.4GHz帯で、CPUにIntelのPXA271を使用したセンサネットワークである。振動台実験においては、Imote2の無線基盤(IPR2410)に3軸方向の加速度計測に対応したセンサ基盤(ITS400)を接続して計測を行った。加速度センサの定格加速度は±2gで、分解能は12bitである。

### (2) 実験方法

無線センサノードは図-5に示すように設置した。センサ名については、模型最下部のスラブの計測を行ったセンサを「無線ノード1」とし、最上部のスラブの計測を行ったセンサを「無線ノード2」とした。加速度の計測は、ブレイシング(筋交い)の有無により表-2に示す3つの構造モデルA、B、Cについて行った。サンプリングレートは全て10msとし、約15秒間計測を行った。構造モデルB及びCのブレイシング




図-5 実験用モデルとセンサの設置場所

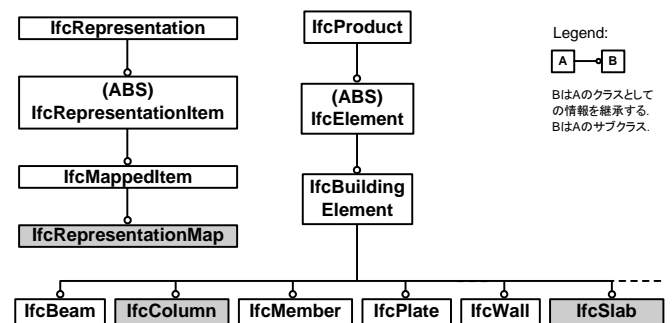


図-6 IFCのクラス図(一部)

には直径0.55mmのステンレス製の針金を使用し、各階層の対角線上にあるL字型の金具に結びつけて設置した。振動のパターンについては、表-3に示すような3つのパターンP、Q、Rを設定し、構造モデル毎に3つの振動パターンで加速度を計測した。表-3のPの振動パターンについては、模型の最上部をハンマーで軽く叩いて自由振動させた時の加速度を計測した。表

表-1 IFC のクラスと統合モデルのテーブルの関係

部材名	データ種別	テーブル名	クラス名
木材	ID	StructuralElement	IfcSlab
	部材長	CrossSection	IfcRepresentationMap
	座標値	Coordinate	IfcRepresentationMap
アルミ板	ID	StructuralElement	IfcSlab
	部材長	CrossSection	IfcRepresentationMap
	座標値	Coordinate	IfcRepresentationMap

表-2 構造モデルとブレイシングの設置箇所

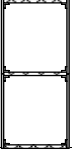
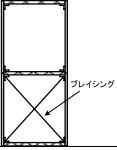
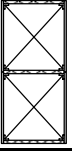
構造モデル名	説明	ブレイシング設置箇所
A	ブレイシングを設置しない場合	
B	1階部分にブレイシングを設置した場合	
C	1, 2階部分にブレイシングを設置した場合	

表-3 振動パターン

振動パターン	説明
P	自由振動
Q	振動台のハンドルを1秒間に1回振動させた振動
R	ランダムな間隔で振動台のハンドルを回振動させた振動

表-3のQとRの振動パターンについては、写真-1に示す振動台の上に模型を設置して加速度を計測した。加速度の計測回数は、表-3のPのパターンでは1回、Q、Rのパターンでは、振動台のハンドルを回す間隔の誤差を考えそれぞれ2回とした。

(3) 実験結果

各構造モデルについて、各振動パターンで得られた加速度波形のうち、無線ノード2の加速度データの一つを図-7に示す。無線ノード1についても同様なデータを得た。尚、データ名については、構造ケース名と振動パターンをハイフンでつないで表すこととした。従って、構造モデル名がAで振動パターンがPの場合




写真-1 振動台に実験用モデルを設置した様子

のデータ名はA-Pとし、構造モデル名がBで振動パターンがPの場合のデータ名はB-Pとした。また、計測を二回行った振動パターンQとRについては、データ名の最後に①または②を付けて区別することとした。従って、構造モデル名がCで振動パターンがQの場合、一回目の計測であればデータ名はC-Q①とし、二回目の計測であればデータ名はC-Q②とした。

実験によって得られた加速度データと構造モデルの部材データは、実験後に本研究で開発した図-3のデータモデルに基づいてデータベースに登録した。その結果、本研究で想定したセンサとセンサが配置されている部材に関するデータを登録することが可能であることが確認された。表-4にデータベースに登録したデータの一部としてスラブのデータ登録内容を示す。また、データベース内に格納されたデータの検索例を図-8に示す。

5. 統合モデルのデータマイニングへの応用

(1) データマイニングの実施方法

4. で記した振動実験によって得られたデータを使用してデータマイニングを行った。また、データマイニングツールにはSPSS社のClementine Desktop 9.0<sup>11)</sup> (以下Clementine)を使用した。データマイニングに用いるデータとしては、表-5に示す6種類の変数を用いることとした。 $\alpha$ は最大加速度であり、 $f$ とは加速度データから作成したフーリエスペクトルの卓越振動数であり、 $T'$ とは加速度データの振幅が最大値から1/10になるまでの時間である(図-9)。 $a$ につい



を構築し、データ番号 10 から 15 の 6 件のデータの構造モデル名の予測を行った。予測モデルの学習アルゴリズムには Clementine の「拡張剪定」を使用し、学習のサイクルは 10,000 回に設定して行った。拡張剪定とは、学習中に入力層と隠れ層の素子の数を剪定することによって、ニューラルネットワークのモデルを構築するアルゴリズムである。

Clementine では、構築されたモデルの入力変数の重要度分析を行うことが可能である。また、分析結果を「相対重要度」として出力することが可能である。そこで、ニューラルネットワークの入力変数には、まず、表-5 の変数を全て使用してネットワークモデルを構築して表-5 の変数間の重要度の分析を行うこととした(表-7 X<sub>1</sub> 列)。出力層には構造モデル名 (A, B, C の何れか) を出力させるための素子を一つ配置した。入力変数の重要度分析の結果、表-8 に示す重要度分析の結果を得た。また、表-5 のデータ番号 10 から 15 の 6 件のデータを入力して予測を行ったところ、C-R②の構造モデル名以外については正しい出力を得ることができた(表-9)。

次に、表-8 に示す入力変数の相対重要度の結果を考慮して変数の選定を行った。表-8 では、 $f_1$  及び  $f_2$  の値が 0.5 付近で他の変数よりも高い値を示している。一方、 $T_1$ ,  $T_2$ ,  $\alpha_1$  が 0.3 付近で近い値を示している。そこで、 $f_1$ ,  $f_2$  を固定し、3 つ目の変数に  $T_1$ ,  $T_2$ ,  $\alpha_1$  の何れかを設定して、Clementine の「拡張剪定」のアルゴリズムによって予測モデルを構築した。その結果、入力変数を  $\alpha_1$ ,  $f_1$ ,  $f_2$  とした場合(表-7 X<sub>2</sub> 列)に、予測対象の全ての構造モデルについて正しい出力を得ることが出来た(表-10)。この時の予測モデルの図を図-10 に示す。

### (3) 考察

振動台実験によって得られたデータを用いて、ニューラルネットワークにより予測モデルを構築し、対象構造のブレイシングの設置数の予測を行った。表-5 の全ての変数を入力変数として設定した場合、誤った値が 1 件出力されたものの、入力変数の重要度分析の結果を元に入力変数を変更した結果、全ての出力において正しい結果を得ることが出来た。この結果より、入力変数の選定によって予測精度の向上が期待できるものと考えられる。一方、汎化能力の高いニューラルネットワークを構築するためには、今回のデータ数では不十分で、より多くのデータを用いてモデルを構築する必要があるものと考えられる。

## 6. まとめ

本研究では、膨大なセンサデータからの知識発見を

目的として、まず、今後普及が見込まれるセンサ及びセンサネットワークを対象としたセンサデータモデルを開発した。センサデータモデルは、防災科学技術研究所の実大規模の大型震動台設備 E-Defense のために開発したイベントに基づくスタースキーマ型のデータモデルをベースとして開発を行った。

次に、データマイニング等によって有意な知識を発見することができるように、センサに関するデータとセンサが配置されている部材に関するデータを関連付けるため、骨組構造用の簡単なプロダクトモデルを開発し、本研究で開発したセンサデータモデルと統合化したデータモデルを開発した。

さらに、木材とアルミニウム板で作成した実験用構造モデルと無線センサネットワーク Imote2 を使用して振動台実験を実施し、各種データを本研究で開発したデータモデルに従ってデータベースに登録してデータモデルの検証を行った。その結果、本研究で開発したデータモデルでは、本研究で想定したセンサとセンサが配置されている部材に関するデータを登録するこ

表-7 変数の設定内容

変数名	設定名と変数の設定内容	
	X <sub>1</sub>	X <sub>2</sub>
$\alpha_1$	○	○
$f_1$	○	○
$T_1$	○	
$\alpha_2$	○	
$f_2$	○	○
$T_2$	○	

表-8 各変数間の相対重要度

変数名	$f_2$	$f_1$	$T_1$	$\alpha_1$	$\alpha_2$	$T_2$
相対重要度	0.55	0.50	0.38	0.35	0.33	0.17

表-9 ニューラルネットワークを用いた予測結果 (設定名 X<sub>1</sub>)

データ番号	実験 構造モデル名	予測 構造モデル名	予測結果
10	A	A	○
11	A	A	○
12	B	B	○
13	B	B	○
14	C	C	○
15	C	A	×
正解数			5

データ番号	実験 構造モデル名	予測 構造モデル名	予測結果
10	A	A	○
11	A	A	○
12	B	B	○
13	B	B	○
14	C	C	○
15	C	C	○
正解数			6

表-10 ニューラルネットワークを用いた予測結果  
(設定名  $X_2$ )

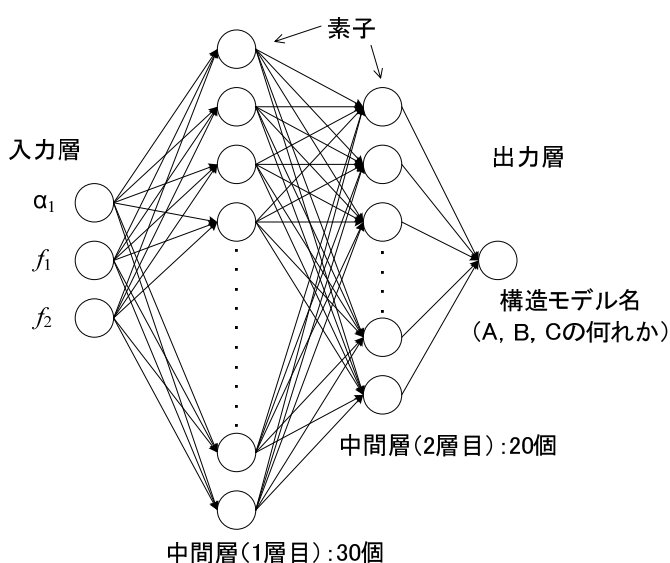


図-10 Clementine で構築されたニューラルネットワーク

とが可能であることが確認された。また、Event テーブルによるテーブル同士の関連付けにより、センサとセンサが取り付けられている部材の関係を正確かつ分かり易く表現することが可能となった。最後に、統合モデルに従って格納したデータを用いてデータマイニングを実施した。データマイニングにはニューラルネットワークを用い、構造モデルの推定に利用可能であ

ることが確認された。

今後の課題は、構造力学に関する定性的なデータ等を付加してデータマイニングを実施し、より有意な知識を発見することだと考えられる。

### 謝辞

本研究は、独立行政法人日本学術振興会の科学研究費補助金基盤研究(C) 課題番号 19560470 及び独立行政法人防災科学技術研究所の「実大三次元震動破壊実験施設 (E-ディフェンス) を活用した国内外共同モデル研究」の援助にて実施した。ここに記して謝意を表す。

### 参考文献

- 1) Peng, J. and Law, K.H.: A Brief Review of Data Models for NEESgrid, NEESgrid TR-2004-01, 2004.
- 2) Peng, J. and Law, K.H.: Validity and Usability of the NEESgrid Reference Data Model, NEESgrid TR-2004-44, 2004.
- 3) 矢吹信喜, 吉田善博: EDgrid (E-Defense Grid) のデータモデルの提案, 第 61 回年次学術講演会講演概要集, 土木学会, pp.549-550, 2006.
- 4) 矢吹信喜, 吉田善博: EDgrid (E-Defense Grid) におけるデータモデルの開発, 土木情報利用技術論文集, Vol.15, pp.111-118, 2006.
- 5) T. J. ティオリー (原田勝訳): データベースの設計, 勁草書房, 2000.
- 6) ISO10303, Industrial Automation Systems and Integration - Product Data Representation and Exchange, 1994.
- 7) IFC: <http://www.iai-international.org/index.html>
- 8) MySQL: <http://www.mysql.com>
- 9) ifcXML: [http://www.iai-international.org/Model/IFC\(ifcXML\)Specs.html](http://www.iai-international.org/Model/IFC(ifcXML)Specs.html)
- 10) Imote2: <http://www.xbow.jp/imote2.pdf>
- 11) SPSS: <http://www.spss.co.jp/>