

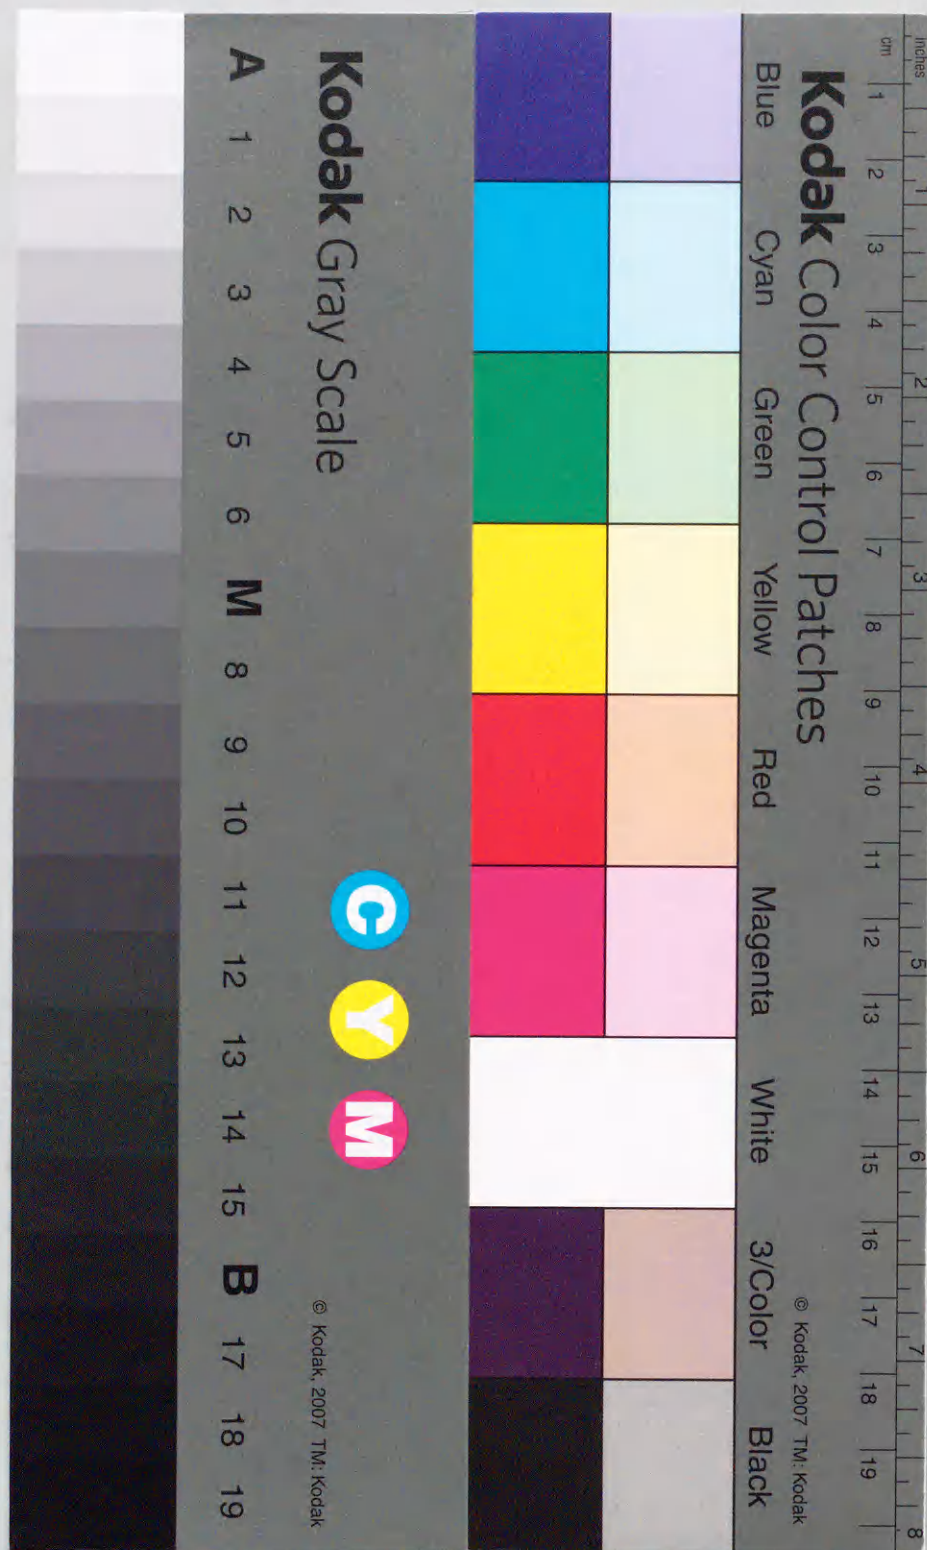
リモートセンシングデータを用いた山地斜面崩壊
の検知手法と災害監視GISに関する研究

1998年3月

博士(工学)

辻子裕二

豊橋技術科学大学



①

リモートセンシングデータを用いた山地斜面崩壊
の検知手法と災害監視GISに関する研究

1998年3月

博士(工学)

辻 子 裕 二

豊橋技術科学大学

リモートセンシングデータを用いた山地斜面崩壊の検知手法と 災害監視GISに関する研究

和文要旨

本研究は地球観測衛星画像を用いて広域に分布する山地斜面崩壊を精度よく検出する方法を提案し、その精度検定を行うとともに、リモートセンシングデータを用いた斜面災害監視GISについて新たな構想を示したものである。

本論文は7章からなる。

第1章では、研究の背景、目的、内容ならびに論文の構成について記述している。

第2章では、被災地全域の土地被覆状況を衛星画像を用いて把握する手法として、マルチスペクトルデータを多層多段のニューラルネットワークにより分類する手法を新たに提案している。また、細密数値情報に含まれる土地利用データと提案手法による分類結果を土地利用形態の複雑な名古屋市について比較し、提案手法の分類精度の検証を行った結果を示している。

第3章では、被災直後においてグラウンドトゥールス(GT)データの取得が困難な場合を想定し、教師データとしてのGTデータの信頼度をマルコフ確率場に基づく時系列での因果律および平面的な因果律により与え、ニューラルネットワークにより衛星画像の土地被覆分類を精度よく行う方法を提案している。さらに、提案手法の分類精度について吟味した結果を示している。

第4章では、被災前後の地形変化などを検出するためにMathematical Morphologyを用いた定式化により、対象領域におけるVNIR画像から地形境界を検出する手法を示している。

第5章では、被災領域が広域に及び、短期間での地上の調査が困難である山地を対象とし、植生と崩壊土砂の混在画素の平面的な分布特性を分析し、Mathematical Morphologyを用いて斜面崩壊規模・崩壊形態をLANDSAT/TMのIR画像から正確に検出する手法を新たに提案している。また、1995年兵庫県南部地震による六甲山系における斜面崩壊事例などに対して提案手法を適用し、高い精度が得られることを示している。

第6章では、前章までに提案された手法を統合し、二次災害危険度評価などを可能とする、広域な被災地を対象とする斜面崩壊監視のための地理情報システム(GIS)を提示するとともに、その適用結果について吟味している。

第7章では、本研究で得られた結論を総括し、今後の展望について述べている。

本研究は地球観測衛星画像を利用した広域斜面災害監視のための有効な手法を提案したものであり、その工学的意義は大きい。

A METHOD OF SLOPE FAILURE DETECTION AND HAZARD MONITORING
GEOGRAPHIC INFORMATION SYSTEM USING REMOTELY SENSED DATA

ABSTRACT

In Japan many steep mountains exist in which weathering soils are frequently encountered. Therefore earthquake- or rainfall-induced slope failures have been occurring and they have brought serious damage to precious lives and properties. If the slope failures can be accurately extracted the emergency evacuation path can be located easily. Also by investigating the significance of the other factors influencing the slope failures the characteristics of the collapsed area can be grasped and the knowledge can contribute to prevent future damages. Generally, slope failures of mountain side are extracted by deciphering aerial photographs and VTRs. Recently satellite remote sensing data such as LANDSAT/TM, /MSS, NOAA/AVHRR and SPOT/HRV are widely used for monitoring the surface condition. For example, TM data provides an image of about 180 km by 180 km area at a time and can be taken periodically. Therefore the continuous hazard monitoring can be easily carried out.

From the points of view, this paper describes a accurate slope failure detection method for large scale mountain side using remotely sensed data. The method is applied to slope failures triggered by 1995 Hyogo-ken Nambu Earthquake.

This paper consists of seven chapters.

Chapter 1 shows the purpose and the background. Then effectiveness of satellite data for hazard monitoring and the way of data selection based on the relation between required information and spectral characteristics are introduced. Also, various previous studies using satellite data and the positioning of methodologies of this study are explained.

Chapter 2 shows several land cover classification methods using multispectral data. Particularly, neural network models that is not necessary to suppose the likelihood to an arbitrary distribution such as Gaussian and is effective to non-linearly separable data are investigated. Then a multi-step neural network model that improves the separability and the statistical stability is proposed and is compared with a conventional neural network model, a statistical method (Maximum Likelihood Classifier) and a fuzzy method. The methods are

applied to Nagoya data and are compared with the detailed land use information of central Japan, TDT-112.

After a hazard, “the reliability” of GT (ground truth) data becomes worse. A method to give the reliability of GT data by “the causalities” based on Markov random field is introduced in chapter 3. It is expanded to a method evaluating the spatial dependencies between neighboring pixels and a post-processing. This method is applied to Nagoya data and is compared with neural network models without MRF causalities. The state probabilities are calculated from detailed land use information TDT-112 and TDT-113.

Chapter 4 shows a method that detects topographical feature changes using VNIR data. Mathematical Morphology that is effective to detect the objects having regularity about the forms is used for the formulation. WNED algorithm based on Mathematical Morphology is proposed and applied to river edge detection.

A method to estimate the scale/shape of slope failures by using IR data is explained in Chapter 5. To improve the accuracy, the slope failure type is distinguished from the distribution of soil/vegetation mixed pixels in the first step. This method is applied to the detection of slope failures triggered by 1995 Hyogo-ken Nambu Earthquake and triggered by heavy rainfall after the earthquake.

Chapter 6 unifies all of methods mentioned in the previous chapters and defines hazard monitoring geographic information system to predict the risk of post hazard in damaged area.

Final chapter summarizes the results obtained in this paper and explaining an overall conclusion.

目次

CONTENTS

第1章 序論	1
1.1 研究の背景と目的	2
1.1.1 研究の背景	2
1.1.2 研究の目的	3
1.2 研究の着眼点	3
1.2.1 対象とする斜面災害	3
1.2.2 災害監視 GIS が有効な時間帯	4
1.3 既往の研究と本研究との関係	5
1.3.1 衛星データの画像解析に関する既往の研究	5
1.3.2 GIS を用いた防災システムに関する既往の研究	8
1.4 本論文の構成	8
第2章 マルチスペクトルデータを用いた土地被覆状態の推定方法	11
2.1 概説	12
2.2 土地被覆分類における問題点と知的情報処理技術の効用	12
2.3 多段ニューラルネットワークによる土地被覆分類手法	13
2.3.1 多段ニューラルネットワークの概要	13
2.3.2 ニューラルネットワークにおける環境変化の与え方	17
2.3.3 バックプロパゲーション学習原理とデータの与え方	17
2.4 ケーススタディー	18
2.4.1 対象地域と使用データ	18
2.4.2 テストケース	19
2.4.3 クラス分離特性	19
2.4.4 推定の精度	20
2.4.5 従来法との比較	21
2.5 結語	29

第3章 GT データの不整を考慮した土地被覆状態の推定方法	31
3.1 概説	32
3.2 GT データが不整を有する環境と問題点	32
3.3 GT データの不整に対するマルコフ確率場の与え方	33
3.4 時系列での因果律の算定	34
3.5 平面的な因果律の算定	37
3.6 ポスト処理への拡張	37
3.7 ケーススタディー	39
3.7.1 対象地域と使用データ	39
3.7.2 解析に用いたニューラルネットワーク構造	39
3.7.3 テストケース	39
3.7.4 推移確率行列の算定結果	41
3.7.5 学習収束に対する安定性評価	41
3.7.6 処理の安定性	45
3.7.7 ポスト処理の効果	45
3.7.8 処理の汎用性	48
3.8 結語	48
第4章 VNIR データを用いた地形変化の検出方法	53
4.1 概説	54
4.2 被覆状態の把握における境界検出の有効性と Morphology の効果	54
4.3 Morphology 演算	55
4.3.1 Morphology の種類	55
4.3.2 陰影変換と表面変換	55
4.3.3 基本演算	56
4.3.4 Morphology 的フィルタリング	57
4.3.5 多重スケールフィルタリング	57
4.4 Morphology による境界検出式	57
4.4.1 代表的な境界検出式	57
4.4.2 多重 Morphology 演算による境界検出式	58
4.5 ケーススタディー	61
4.5.1 対象地域と使用データ	61
4.5.2 構成要素	61

4.5.3 従来法と多重式の適用結果の比較	62
4.5.3 サイズの拡大による WNED の効果	66
4.6 結語	67
第5章 IR データを用いた山地斜面崩壊の規模・形状の推定方法	69
5.1 概説	70
5.2 斜面崩壊検知における衛星データの有効性と Morphology の効果	70
5.3 斜面崩壊検知の基本的な考え方と Morphology の効用	71
5.4 検知対象とする斜面崩壊形態	71
5.5 斜面崩壊検知に用いるパラメータ	72
5.5.1 崩壊面積と DN との関係	72
5.5.2 崩壊面積と DN の平面的な広がり方との関係	73
5.5.3 斜面崩壊地点の検知手法の流れ	73
5.6 ケーススタディー	78
5.6.1 対象地域と使用データ	78
5.6.2 精度評価の考え方	78
5.6.3 同一時刻のパラメータを用いる場合の精度	81
5.6.4 パラメータの汎用性	82
5.7 結語	83
第6章 リモートセンシングデータを用いた災害監視 GIS	89
6.1 概説	90
6.2 斜面崩壊のメカニズムと衛星データを用いた崩壊予測の概念と事例	90
6.2.1 斜面災害危険度の概略的な予測手法	90
6.2.2 斜面災害危険度の詳細な予測手法	90
6.2.3 各自治体における斜面崩壊危険度の予測手法	90
6.3 災害監視 GIS の要件	94
6.3.1 災害監視 GIS の考え方とその必要性	94
6.3.2 二次災害推定の考え方と在来法との比較	94
6.3.3 斜面崩壊検知結果の二次災害監視への有効性	95
6.4 二次災害発生予測図の作成方法	96

6.5 ケーススタディー	97
6.5.1 ケーススタディーの概要	97
6.5.2 素因と崩壊地点との関係	97
6.5.3 二次災害危険度推定値の算定	102
6.6 結語	104
第7章 結論	107
謝辞	109
参考文献	110

第1章 序論

CHAPTER 1 INTRODUCTION

In Japan many steep mountain regions exist in which weathering soils are frequently encountered. Therefore earthquake- or rainfall-induced slope failures have been occurring and they have brought serious damage to precious lives and properties. Especially, the slope failures triggered by the 1995 Hyogo-ken Nambu Earthquake have continued throughout a long period of time and the total number of collapsed slopes were more than several hundred. If the slope failures can be accurately extracted the emergency evacuation path can be located easily. Also by investigating the significance of the other factors influencing the slope failures the characteristics of the collapsed area can be grasped and the knowledge can contribute to prevent future damages.

Generally, slope failures in mountain regions are extracted by deciphering aerial photographs and VTRs. Recently satellite remote sensing data such as LANDSAT/TM, MSS, and NOAA/AVHRR are widely used to monitor the surface condition. It has many advantages against VTRs and photographs. TM data provides an image of about 180 km by 180 km area at a time and can be taken periodically. Therefore the continuous monitoring can be easily carried out.

The purpose of this study is to extract the information to be used for the disaster prevention from remote sensing data. Particularly, the detection of slope failures is undertaken. This paper consists of four main topics as follows ;

- (1) Development of accurate land cover classification method (CHAPTER 2 and 3)
- (2) Development of accurate topographical change detection method (CHAPTER 4)
- (3) Development of slope failure detection method for mountain areas (CHAPTER 5)
- (4) Development of GIS to prevent the post hazard (CHAPTER 6).

KEY WORDS : Remote Sensing, LANDSAT/TM, Disaster Prevention, GIS, Slope Failure, Mountain Side, Earthquake, Heavy Rainfall

1.1 研究の背景と目的

1.1.1 研究の背景

急峻な山地と風化土が数多く存在する我が国は、地震や降雨によって斜面災害が発生し、貴重な生命や財産に甚大な被害を受けることが多くみられる。とくに、1995年兵庫県南部地震によって脆弱な風化花崗岩を有する六甲山系に生じた斜面崩壊は、同地震を直接の誘因としたもの、およびその後の集中降雨を誘因としたものと長期にわたり崩壊が継続し、総数は数百を数えた。斜面崩壊の発生した地点を早期にかつ的確に把握すれば、その分布図から緊急避難計画や応急復旧計画に対して有効な資料を提供できる。また、その他の素因との関連性を調べることにより、被災箇所の特性が判断でき、二次災害の防止に寄与できる。

一般的に、山腹斜面災害の把握は航空写真やヘリコプターからのVTRの判読や時間がある場合には踏査によって行われる。しかし、人間の判断を介する場合は、判読者の確保、判読に要する時間、判読者の熟練度の差異による判読精度等の問題が指摘できる。また、航空機やヘリコプターの使用にあたっては、経済的な負担はもちろんのこと、定期的な観測を行うことが困難といえる。定期的な観測が困難であることは、災害が生じた時刻の推定が曖昧になり、事象解明のための因果関係の検討に不確定要素を残す。さらに、航空写真やVTRを用いる場合には、被災箇所の観測で得られた情報の整理、すなわち被災情報のデータベース化について、デジタル化や幾何学的補正に対する困難さが問題点として挙げられる。

以上から導かれる斜面災害の広域な把握を早期に実現するためのデータの条件は、以下のように整理できる。

- ① 少なくとも国内であればどの地域でも利用できるデータであり、利用者の制限がない。
- ② 任意の処理によって、地域間での汎用性が確保される。
- ③ 少なくとも我が国における地方自治体の行政単位を包含する程度の広域な対象を、同程度の精度で一度（瞬時）に把握できる。
- ④ 同程度の精度で、時系列観測が可能である。
- ⑤ 位置参照が明確である。

これらの条件を満足するデータソースとして、本研究では衛星データを取り扱う。LANDSAT/TMデータを例にとれば、約180km四方（広域性）の撮影が同時に行え（同時性）、再訪時間が16日（周期性）であり、かつ航空写真に比して極めて廉価（経済性）である。また、過去のデータの蓄積があるため、被災履歴の把握にも適している。さらに、得られる情報は8ビットに量子化され、処理状態によっては任意の地図

投影法（日本におけるLANDSAT/TMデータは通常UTM）に従うことから、データベース化および情報の重ね合わせも容易となる。

以上より、衛星データを用いた広域な対象の継続的なモニタリングの有用性が判断できる。とくに、山腹のように踏査が困難な場所における概括的な調査に対しては、その安全性も含めて重要な利点と考える。

1.1.2 研究の目的

本研究は、衛星データを用いて広域に分布する斜面災害（斜面崩壊）を精度よく検出する方法を提案し、その精度検定を行うとともに、衛星データを用いた斜面災害監視GISについて新たな構想を示すものである。

斜面災害の詳細な把握を実現するために、まず、被災地全域の精度の高い土地被覆分類図を作成する手法を提案する。つぎに、衛星データの物理特性を踏まえた上で対象を規則性のある地形に限定し、被災前後の地形変化などを検出する手法を提案する。以上の提案式により被災の程度を概略的に把握した上で、対象を山腹斜面に限定し、斜面崩壊規模・崩壊形態を正確に推定する手法を新たに提案する。

以上のような対象レベルに応じた検出方法を、被災時および被災後の解析あるいは知見の整理に有用なものとするため、地理情報システム（Geographic Information System : GIS）の考え方に基づいて統合する。このGISは災害監視を主とした目的とすることから災害監視GIS（Hazard Monitoring GIS : HMGIS）として記述する。災害監視GISにより、検知された情報から応急復旧計画における避難経路情報等を提供することが可能となる。本研究では、災害監視GISの応用場面として対象領域内の地点に初期的な災害と同様の災害が発生する可能性（危険率）を出力する例を検討する。

各手法の検証は、中部地域で細密数値情報のような精度の高い検証データが整備されている愛知県名古屋市、および1995年兵庫県南部地震において被害の見られた六甲山系を対象にしたケーススタディーにより行う。

1.2 研究の着眼点

1.2.1 対象とする斜面災害

斜面崩壊（slope failure）は地すべり（landslide）とともに斜面災害の二大要素である。一般的に、前者は突発的かつ局所的に発生する事象として定義される。これに対し後者は平均的に数1000m²以上に及ぶものもあるほど大きく、土塊の移動速度が緩やかで断続的あるいは継続的であるものを指す。また、地すべりは限られた地質条件下で集中する傾向がある。

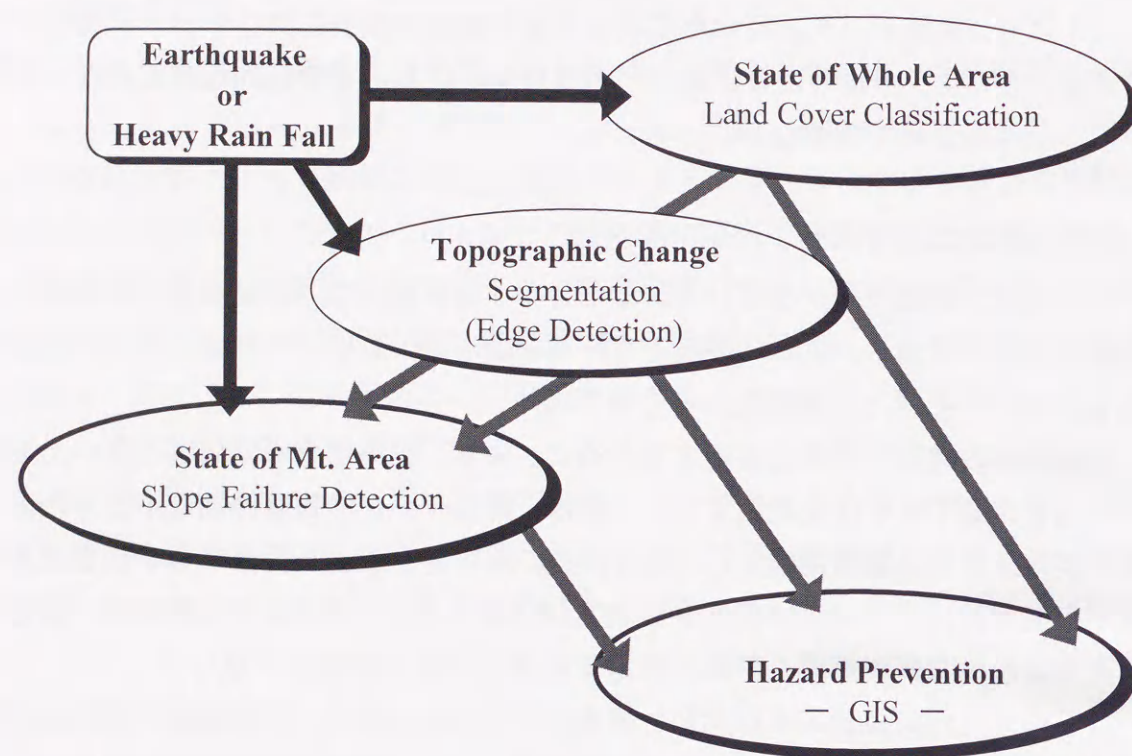


Fig. 1-1 Overview of this study

この定義から地すべり地域の推定は連続的な地盤計測により、ある程度の信頼性をもって可能である。ただし、この場合は定点として観測体系が整備されていることが条件となる。先の1995年兵庫県南部地震による斜面災害に見られるように、また定義からも推察できるように、斜面崩壊は広域に渡って任意の誘因により短時間に発生するため、その点的決定は極めて困難である。以上より本論では斜面崩壊を対象とする。

1.2.2 災害監視GISが有効な時間帯

災害監視GISは、災害発生時刻を基準とした経過時間に応じて機能が割り当てられる。一般的に、住民の行動に基づいた震災時の場面は以下のように区分される¹⁻¹⁾。

- ① 被災期（～10分）：地盤被害や構造物・施設が破壊され、出火、ライフライン等の破壊が各所で発生し、日常の諸行動が停止する。
- ② 混乱期（10分～1時間）：火災や浸水等の二次的被害の発生による混乱が起こ

る。情報収集ができず、行動ができない状態に陥る情報空白期。

- ③ 避難・救助期（1時間～3日）：火災や浸水等の二次的災害が拡大し、救助活動や住民避難行動・救助活動が開始される。
- ④ 応急復旧期（3日～1週間）：被害状況が判明し、行方不明者の捜索、ライフラインの復旧が始まる。
- ⑤ 復旧期（1週間～3ヶ月）：被害建築物の取り壊し、仮設住宅の建設が始まる。日常生活に関わる諸問題が発生する。
- ⑥ 復興期（3ヶ月～）：まちが活気を取り戻し、施設・住宅の再建が始まり、広域的な復興政策が始まる。

災害監視GISは被災期から復興期までの全期間でその役割を担う。本研究の命題は斜面崩壊の把握と二次災害の監視であることから、対応する場面は混乱期から復興までの長期に渡る。しかし、衛星データが処理可能となるまでには、再訪時間と前回撮影時刻および前処理の関係で数日必要となる。ただし、山地における被災状態の把握は、人的被害への対応の次段階と考えられるため、衛星の再訪を待つ猶予が与えられる。仮に、他の方法で山腹の被災状態を全域に渡り把握しようと試みる場合、その前処理の複雑さから莫大な時間を要し、かつ精度も判読者により異なることからデータベースとしての信頼性も問われる。以上より、本研究が必要となる時間帯が事象発生から数日経過した後とされることの問題は希少であると判断される。また、今後データの多様化に伴い衛星の再訪時間が短縮されることも特筆すべきである。

1.3 既往の研究と本研究との関係

1.3.1 衛星データの画像解析に関する既往の研究

衛星データは、光学センサーにより地表からの放射輝度を測定する、いわゆるPassiveデータと、マイクロ波などのような電磁波をプラットフォームから照射し、その反射エネルギーを取得するActiveデータに大分類できる。Passiveデータは可視域のデータを含むため、人間が見る感覚と同様の基準で対象を判別できる。また、赤外域のデータを利用することにより、植生の活力度の判定や熱の分布状態を把握することができる。

Passiveデータは通常マルチスペクトルデータとして与えられるので、高次元の多変量解析により土地被覆状態の推定が比較的容易となる。マルチスペクトルデータを解析する方法で最もよく用いられてきた手法は教師データを多次元正規分布にすり合わせて統計的な最適解を得る最尤法（Maximum Likelihood Classifier: MLC）である¹⁻²⁾。この方法は教師データの分布が単峰形を示すデータである場合に適度に安定した解

を出力するが、絶対精度不足から高度な情報処理技術を用いた方法が種々提案されてきた。ニューラルネットワーク¹⁻³⁾やファジー理論¹⁻⁴⁾、遺伝的アルゴリズム(GA)を用いた方法である。本論の第2章ではニューラルネットワークに関する検討が紹介される。

これら知的情報処理技術により、理想的な教師データが得られる場合には良好な結果を得ることが可能となった。しかし、東南アジア地域のように教師データを整備するための資料が不足する地域の解析にあたっては、教師データの信頼性が不明確となることにより極端な精度の劣化が生じる場合もある。日本国内においても被災直後は極端に被覆状態が変化するため、教師データの信頼性が劣化することが予想される。このような場合に対処する方法として、教師データのクラス間の分離度を計算し、これを判断材料として最適解を与える事例も存在する。しかし、これらは統計的な判断に基づくことから、最尤法と同様の問題が指摘できる。この点に関して本論では、第3章で教師データの信頼性の評価方法を検討している。

以上のような方法で、マルチスペクトルデータからシーン全体の被覆状態を把握することが可能となる。しかし、これらは多変量解析という数学的な概念から最適解を出力するものであり、Passiveデータの物理的特性を含んではいない。Passiveデータの近赤外域のデータ(TMではバンド4に相当)と赤色域のデータとの比演算で計算される正規化植生指標NVI(Normalized Vegetation Index)は植生活性度と強い相関を示すことが確認されている。また、NVIと逆相関にある都市化の程度は、TMの場合バンド7とバンド4との比演算により与えられるとする事例がある^{1-5)・1-10)}。これらの特徴を利用して、着目領域のレベスライスや境界検出が可能となる。災害時における山腹あるいは急傾斜地で生じる大規模な地形形状の変化も、このようなデータから2次的なデータへ変換することにより抽出できる。本論では、第4章でVNIRデータから地形変化を検出する方法が紹介される。

Passiveデータを用いて地盤の状態を知るには中間赤外域のデータ(TMではバンド5に相当)の寄与率が高いとされる^{1-11)・1-12)}。バンド5が含水状態を良好に反映するためである。この特徴を利用し、数量化理論を用いて興味のある結果を出力した事例も数件存在する。また、1995兵庫県南部地震前後には熱映像(TMではバンド6に相当)に特徴的な変化があったとする報告もある¹⁻¹³⁾。ただし、一般的にはTMのバンド6は空間解像度および量子化の解像度共に他のバンドに比して劣り、小規模な斜面崩壊を検出する場合には適さないことが多い。また、他の地理データを入力として与える場合もあるが、この場合詳細な地形データの寄与率が衛星データのそれに対して高く評価され、衛星データを用いる意味合いが薄れている。

衛星データの寄与率が低い理由として、画素単位の解析の影響が考えられる。TM

データの場合は解像度が約30mであり、この中に複数の被覆クラスが混在する場合には、画素はミクセル(Mixed Pixel or Mixel)として現れる。任意の混在率で畳み込まれるミクセルの輝度値を画素単位に解析すれば、ノイズの多い出力図が出来上がる。これに対処するには、隣接画素との関係性を処理に組み込むことが必要となる。前処理としてフィルタリングを施す例もあるが、画像の質を低下させるため小さな斜面崩壊を求める場合には不適である。ここで、被覆クラスの混在率の組み合わせは天文学的な数になるため、被覆状態をある程度制限することが望まれる。山腹における斜面崩壊を検出する場合は、日本の場合緑被域と崩壊土(裸地)に限定することができる。この場合の処理方法は、本論第5章で紹介される。

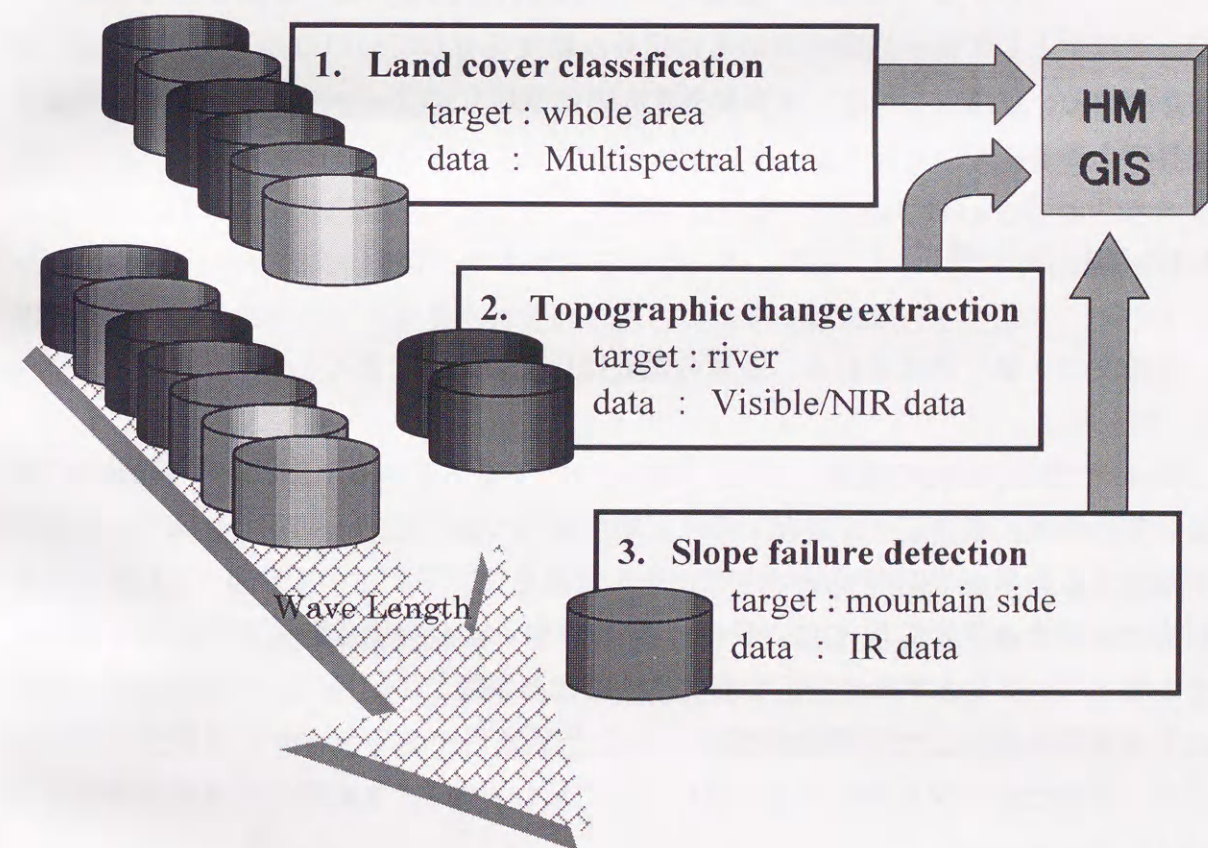


Fig. 1-2 Relation between target output and required data (the case of LANDSAT/TM)

1.3.2 GISを用いた防災システムに関する既往の研究

GISは一般的に、データベース管理システム(DBMS)、データ解析システムおよびデータ表示システムから構成される。DBMSは地理情報の入力・検索・修正・加工を行う重要な役割を担う。災害時に望まれるDBMSは、平常時における地表から地下までの全ての情報を有する必要がある。しかし、実際には使用するデータの精度、とくに解像度が目的に応じて異なることから、必要なデータに優先順位を設定し、上位から順に整備を図る事例が多くみられる。現在公表されているGISとして、道路地図データベース¹⁻¹⁴⁾、水道やガス、電気などのライフラインを詳細に記述したもの等が挙げられる。これらはcm単位、ときにはmm単位でのデータの精度が要求されるため、全国をカバーする共通データベースではない。建設省国土地理院では積極的に既存データを数値化し、フロッピーディスク単位で「FDマップ」として一般に有償で配布している¹⁻¹⁴⁾。また、国土地理院が中心となって、データの共用を潤滑にすることを目的として先述「空間データ基盤整備」¹⁻¹⁸⁾も進められている。これに並行するかたちでISOによる標準化(基準化)¹⁻¹⁴⁾も検討されている。本論6章で使用するデータは主として斜面崩壊を求めるに足る精度を有していれば良く、FDマップで対応できる。また、これは広域を解析するのに適度なパフォーマンスを示す現段階の限界でもある。

1.4 本論文の構成

本論文は7章で構成される。各章の概要は以下のようである。

(1) 第1章

第1章では本研究の背景、目的、内容について述べている。1.1節では被災時の被災状態の把握に衛星データを用いることの利点について記述している。また、本研究で提案する衛星画像処理手法の内容とその役割について記述している。1.2節では本研究で定義する災害監視GISが対象とする事象および有効な時間帯について記述している。1.3節では本論に関係する既往の研究と本論との関係について記述し、種々の災害監視を行う上で必要な情報のレベルと衛星データのスペクトル特性との関係から、有効なデータを選択する方法について示している。1.4節では本論の構成について記述している。

(2) 第2章

第2章では被災地全域の土地被覆状態を衛星データを用いて把握する手法として、マルチスペクトルデータの分類手法を新たに提案している。とくに、尤度関数を任意

の分布形に仮定する必要がなく、非線形分離に対しても有効とされるニューラルネットワークを並列させ、クラス間分離性と統計的安定性を向上させる多層多段のニューラルネットワークについて説明している。また、従来法に対する提示手法の有用性と被災時の急激な被覆変化への対応諸処置策についても触れている。さらに、細密数値情報土地利用情報と提案手法による分類結果を土地利用形態の複雑な名古屋市について比較し、手法の分類精度を検証している。

(3) 第3章

第3章では被災直後にグラウンドトゥールズ(GT)データの取得が困難な場合を想定し、教師データとしてのGTデータの信頼度をマルコフ確率場に基づく時系列での因果律および平面的な因果律により与える方法について示している。さらに、これらの方法をポスト処理にも拡張している。手法の検証は、第2章と同様、詳細なデータが整備されている名古屋市を対象領域としたケーススタディーにより行っている。

(4) 第4章

第4章では対象を規則性のある地形に限定し、スペクトルデータの物理的特徴を利用してVNIRデータの空間分布から地形形状を抽出し、被災前後の地形変化を検出する手法について述べている。とくに、規則的な形状の抽出に対して有効とされるMathematical Morphologyを用い定式化を行っている。手法の検証は、河川水際線の検出を例に、詳細なデータが整備されている名古屋市を対象領域としたケーススタディーにより行っている。

(5) 第5章

第5章では被災領域が広域に及び、短期間での地上の調査が困難である山地を対象とし、植生と崩壊土砂の混在画素の平面的な分布特性を分析し、Mathematical Morphologyを用いて斜面崩壊面積・崩壊形態をIRデータから正確に検出する手法を新たに提案している。また、1995年兵庫県南部地震によって六甲山系に生じた斜面壊事例などに対して本手法を適用し、同時に航空写真からの判読による結果と比較することにより本手法の検証を行っている。

(6) 第6章

第6章では前章までで得られた手法を統合し、広域な被災地を対象とする斜面崩壊監視のための災害監視GISを提示している。災害監視GISの成果の一例として二次的な崩壊危険度の予測を行っている。とくに、在来法に見られるような力学的な作用力

に基づく危険度評価ではなく、初期的な災害の依存度を直接的に反映させるようなGISアプローチについて検討している。手法の検証は、1995年兵庫県南部地震で生じた斜面崩壊を教師データとし、その後の降雨により生じた崩壊を検出対象としたケーススタディーにより行っている。

(7) 第7章

本研究で得られた結果をまとめ、総括的な結論と展望について述べている。

第2章 マルチスペクトルデータを用いた 土地被覆状態の推定方法

CHAPTER 2 LAND COVER CLASSIFICATION USING MULTISPECTRAL REMOTE SENSING DATA

Maximum likelihood classifier that is often used for land cover classification of satellite remote sensing images assumes the distribution of the training data to be Gaussian. Such linear classifiers can classify correctly when the classification probability of each class is exclusive. Remotely sensed data, however, belong to several classes and have non-linear separable condition. To improve the classification accuracy of non-linear separable data, single-step multi-layer back propagation neural networks have been studied by many researchers. In this chapter, multi-step multi-layer neural networks, or so called cooperative learning neural networks, are proposed.

The cooperative learning neural network consists of extraction networks for each classification category and an unification network which unifies the extracted values. The unification network is also used for unification of different environments such as time-series data or neighboring regions. The result of the classification of LANDSAT/TM data of Nagoya city using the cooperative learning neural network is introduced. Classification results are compared with the detailed digital land cover information (TDT-112) and the images classified using single-step multi-layer neural network, maximum likelihood classifier and fuzzy set reasoning. As the result of the comparison, the usefulness of cooperative learning neural network was found more exactly than the other methods.

KEY WORDS : Land Cover Classification, Neural Network, Fuzzy Theory, Maximum Likelihood Classifier

2.1 概説

本章では、被災地全域の土地被覆分類図を、マルチスペクトルデータから推定するための高精度処理手法の一提案を行う。この方法論として、理想的な環境下で精度の高いニューラルネットワークを利用する。とくに、一般的に用いられるニューラルネットワークを多段化する方法について検討する。手法の検証は、細密数値情報土地利用データが整備されている名古屋市を対象領域としたケーススタディーにより行う。また、提案手法と在来型のニューラルネットワークおよび最尤法、ファジー理論による成果と比較する。

2.2 土地被覆分類における問題点と知的情報処理技術の効用

衛星データの分類は通常、教師データにおけるクラス C_i および特徴ベクトル X に対して、確率概念に基づく Bayes の法則に従って行われる。これを、教師データによる先験情報に基づいて事後確率分布の最尤推定法によりクラスが決定される問題として捉えると、この分類問題は $P(C_i|X)$ に対して最大値をとる C_i を決定する問題に帰着する。衛星データの分類に主として用いられる最尤法は、この先験情報に基づく確率密度関数を多次元正規分布に仮定するものであり、特徴空間でのデータの正規性が確保されることを前提条件とする。このため、定義された各クラスの尤度の最大値は唯一特徴空間上の多次元平均値ベクトルとして与えられる。したがって、各クラスの画素の特徴空間上での分布が重なりをもたない、すなわち各クラス毎の生起確率が互いに排反していれば統計的に見て分類誤差は極めて小さくなる。しかしながら、衛星データの場合には、一つの分類クラスに含まれる画素の特徴空間上での分布は必ずしも正規分布に従うものばかりではない。また、分類クラスの設定方法等に起因して、仮定する線形判別関数ではクラス分離が困難な場合もある。このような性質を持つ衛星データのクラス分類手法に関して、バックプロパゲーション学習原理に基づくニューラルネットワークの応用性について多くの研究成果が示されており、その有効性が検証されている^{2-1), 2-2), 2-3)}。ニューラルネットワークを用いた分類では、対象画像の入力ベクトルと目標出力を画素単位で対応させて学習を行っており、画素の特徴空間上での分布の仮定や線形分離の性質を前提とすることなく分類できるとされる。ここに、線形分離が可能であるとは、1 を出力すべきものを $\phi+$ 、0 を出力すべきものを $\phi-$ としたとき、その一次結合、

$$\Omega(\phi) = a_1\phi_1 + a_2\phi_2 + \cdots + a_n\phi_n \quad (2-1)$$

が存在し、

$$\begin{aligned} \phi_s \in \phi+ & \text{ iff } \Omega(\phi_s) > 0 \\ \phi_s \in \phi- & \text{ iff } \Omega(\phi_s) < 0 \end{aligned} \quad (2-2)$$

が成立する場合をいう。すなわち、 N 次元特徴空間を $(N-1)$ 次元超平面で分離できることを示す。ニューラルネットワークは線形分離が困難なデータのクラス分類に対して有効であることが認識されてきているが、クラス分類の対象となる画像の中で各クラスに対応する画素の分布密度に大きな差があるときには（例えば、大都市の中心部のように水域に対して市街地が卓越している場合には）、前述した特徴空間上でのクラス分布の重なりの影響が大きくなる。被災直後には、予め用意された教師データ全てを解析に用いることは困難となり、選択された教師データの分布密度がクラスによって極端に異なることが予想される。このような場合には単一のニューラルネットワークの分類では、十分なユニットを用意し十分な学習を与えなければ、ほぼ等しい特徴ベクトルを有する画素群を正確に区別することは困難となる。逆に、十分なユニット数の確保および学習を許せば、未知画像に対する汎用性（汎化能力）が劣る原因となる。以上の問題に対処するために、各クラスの抽出に適したニューラルネットワークを並列して分類判定を行い、これらを統合することで精度の向上と統計的な安定性を確保する多段のニューラルネットワークが考案された²⁻⁴⁾。

2.3 多段ニューラルネットワークによる土地被覆分類手法

2.3.1 多段ニューラルネットワークの概要

多段ニューラルネットワークは、Fig. 2-1 に示すように、ある一クラスを認識するのに最も適した抽出ネットワークと、複数の抽出ネットワークの出力結果を総合的に判定する統合ネットワークから構成される。通常のニューラルネットワークは一つの抽出ネットワークに相当しており、対象とする画像中で各クラスの画素数に著しい偏りがあるなどにより特徴ベクトルが異クラス間で重複するような場合には、画素数の少ないクラスの抽出は困難となる。いま、教師データとして入力する特徴ベクトルとそれに対応する分類クラスの組 (X, C) に対して、 K 個のクラス間で重複する特徴ベクトル X_{ol} を、

$$X_{ol} = \{X | X \subseteq C_1 \cap X \subseteq C_2 \cap \cdots \cap X \subseteq C_K\} \quad (2-3)$$

と定義する。ただし、 X_{ol} は $X_m - \xi_l < X_{ol} < X_m + \xi_u$ の幅をもつ。 X_m は分離が困難な

X_{ol} のクラス間境界値である。ニューラルネットワークの場合、 ξ_l および ξ_u は中間層ユニット数や学習回数により異なる。一方、ニューラルネットワークの学習とは、任意の X_{ol} と教師信号の組 (X_{ol}, d) に対して、次式で示される評価関数 r の最小化問題として表される。

$$r = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^M (O_{ij} - d_{ij})^T (O_{ij} - d_{ij}) \quad (2-4)$$

ここに、 O_{ij} は X_{ol} を入力ベクトルとするネットワーク出力、 d_{ij} は O_{ij} に対応する教師信号、 N は X_{ol} に含まれるパターン数および M は出力層におけるユニット数である。衛星データの土地被覆分類に一般的に用いられる多層単段のニューラルネットワークは、全学習パターンに対する r を最小化するようにネットワーク出力値を M のうちの何れかに割り当てる問題と考えられる。Fig. 2-3(a)は3クラスの分類における単段ネットワークの学習原理を示したものである。図中、 r を最小化するクラス1とクラス3の境界は、次式で示される X_m により示される。

$$X_m = \{ X \mid H1(X) = H3(X) = \max\{Hi(X)\} \} \quad (2-5)$$

where $i=1,2,3$

すなわち、任意の特徴ベクトル X がクラス1に属するためには、 X_{ol} を入力ベクトルとする画素のうちクラス1に属する画素数が他のいずれのクラスに属する画素数よりも多いことが条件となる。これに対して、多段ニューラルネットワークにおける r の最小化は各クラス（各段）で着目クラスか否かを決定する問題（Fig. 2-3(b)）となり、その境界 X_m は次式で示される。

$$X_m = \{ X \mid H1(X) = (H2(X) + H3(X)) \} \quad (2-6)$$

where $i=1,2,3$

したがって、任意の特徴ベクトル X がクラス1に属するためには、 X_{ol} を入力ベクトルとする画素のうちクラス1に属する画素数が他のクラスに属する画素数の総和よりも多いことが条件となる。つまり、教師データの偏りに伴う X_{ol} の多数決の影響を軽減することができる。また、段数が3（段数が2の場合は単段の解析と同じ）以上では、同じ入力パターンに対して並列されたネットワークで異なった教師信号を与えることで各抽出ネットワーク毎の分離形態を制御することができる。このように複数の抽出ネットワークを並列して機能させる点に多段ネットワークの特徴がある。

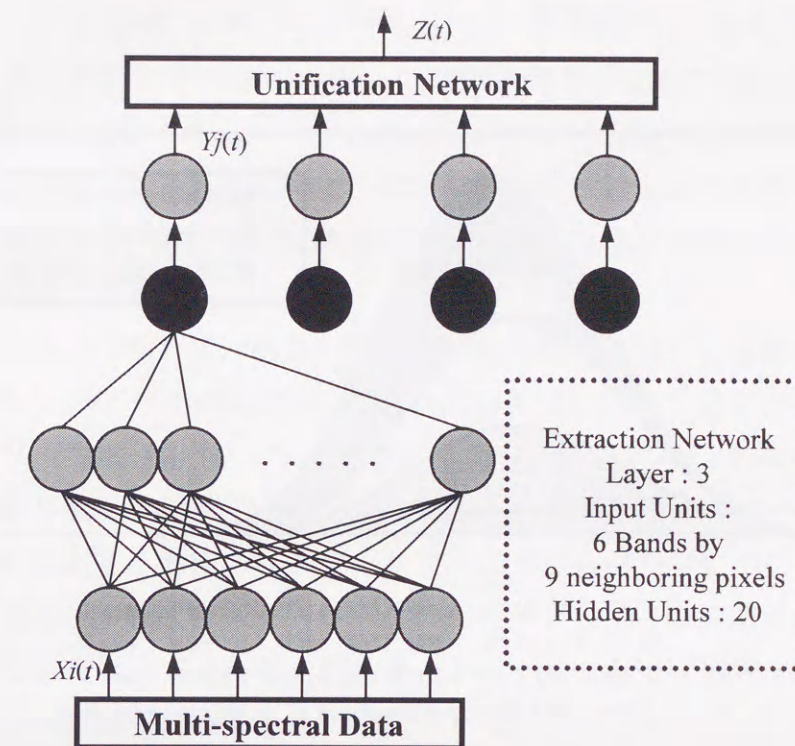


Fig. 2-1 Proposed multi-step neural network architecture (1)

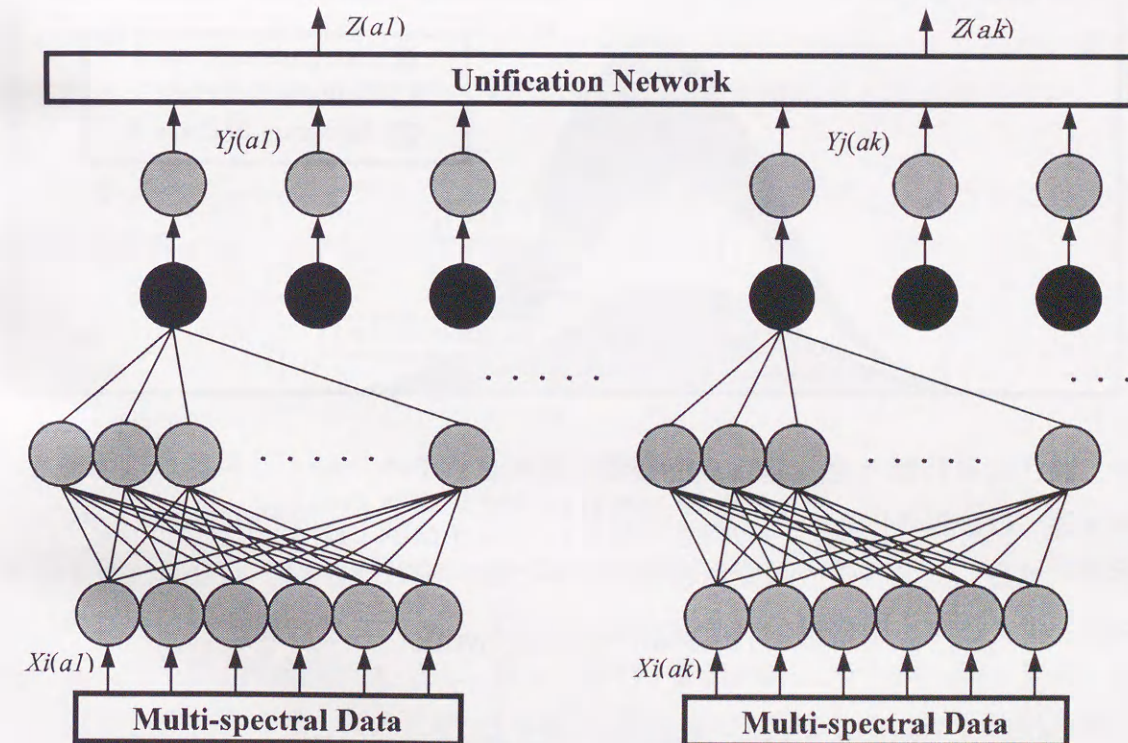


Fig. 2-2 Proposed multi-step neural network architecture (2)





Fig. 2-3 Minimization rule of error function

2.3.2 ニューラルネットワークにおける環境変化の与え方

衛星データは対象とする領域あるいは時刻の環境が同じであっても異なった分類結果を生じたり、対象とするデータの採取そのものに複数クラスの混在等による置換がある場合も考えられる。先述のように、被災直後は被災域内の教師データを採取することが困難なため、選択された教師データの領域特性が分類結果に影響を及ぼすことも容易に推測できる。

このような場合に対して、複数の領域・時刻環境を分担して学習し統合することにより、多段ネットワーク (Fig. 2-3) は統計的な精度の向上と安定化を図ることが可能となる^{2-6), 2-7)}。図中、抽出ネットワークの入力値 X_i はバンド i のスペクトルデータであり、出力値 Y_j は入力画素のクラス j に対する適合度を示す。同スペクトルデータを各クラスを代表する抽出ネットワークに入力し、各クラスについての適合度 Y_j を出力として得る。 Y_j を統合ネットワークの入力値とし、この値より最終的なクラス判定結果として Z を出力する作業を統合ネットワークで行う。添字 i は画素の持つ性質が一樣である画像領域 (画像環境) を代表する。

2.3.3 バックプロパゲーション学習原理とデータの与え方

ニューラルネットワークの学習原理は、Rumelhart と McClelland により提案²⁻⁸⁾され、「任意の非線形写像を任意の精度で近似的に再現可能である」ことが数学的解析結果より証明されている²⁻⁹⁾バックプロパゲーション (Back Propagation) 法が一般的に用いられる。マルチスペクトルデータにこの学習原理を適用する方法は以下のようなものである。

マルチスペクトルデータのバンド i の輝度値を⁰ X_i とすると、入力層に与えられる信号¹ X_i はダイナミックレンジ $D (=255)$ で正規化される。

$$^1X_i = ^0X_i / D \quad (2-7)$$

P 層からなるネットワークを考え、第1層目を入力層、第 P 層目を出力層、それらの間の $(P-2)$ 層を中間層とする正方向の信号伝搬を考える。層間の結合は、第 n 層から第 $n+1$ 層へ結合しているだけで、飛び越した結合はないものとする。また、それらの層間の結合は、全層の全ユニットが互いに結合する完全結合型とする。第 n 層の i 番目のユニットの出力値をⁿ X_i とし、第 $n-1$ 層の i 番目のユニットから第 n 層の j 番目のユニットへの結合の重みを^{n-1,n} W_{ij} とすると、第 n 層の j 番目のユニットの出力値ⁿ X_j は次式で示される。

$${}^n X_j = f_i({}^{n-1,n} W_{ij} \cdot {}^{n-1} X_i - {}^n H_j) \quad (2-8)$$

ここに、 ${}^n H_j$ は閾値である。 f_i は伝達関数であり線形関数、ステップ関数などが挙げられるが、非線形関数であるシグモイド関数が一般的に用いられる。

正方向の伝搬で計算された出力パターンと教師信号（目標出力）との誤差（評価）関数を計算し、それを学習信号として逆方向へ伝播させながら結合の重み、閾値を改善していく。誤差の降下法はいくつか提案されているが、次式は学習の振動を減らし収束を早める項を有する代表的な方法である。

$${}^{n-1,n} \Delta W_{ij}(t) = \varepsilon {}^{n-1} \delta_i {}^n X_j + \alpha {}^{n-1,n} W_{ij}(t-1) \quad (2-9)$$

ここに、 ε は学習定数、 α は安定化定数と呼ばれる。修正された重みは次式となる。

$${}^{n-1,n} W_{ij}(t+1) = {}^{n-1,n} W_{ij}(t) + {}^{n-1,n} \Delta W_{ij}(t) \quad (2-10)$$

閾値の修正量は、 ${}^n X_j \equiv 1$ とみなして次式を得る。

$${}^n \Delta H_i(t) = \varepsilon {}^n \delta_i + \alpha {}^n H_i(t-1) \quad (2-11)$$

よって、修正された閾値は次式となる。

$${}^n H_i(t+1) = {}^n H_i(t) + {}^n \Delta H_i(t) \quad (2-12)$$

収束条件を満たせば学習が終了し分類段階に進む。分類段階においては未知スペクトルデータを学習段階のコーディングに従って読み込み、最終的に決定された重み・閾値を用いて正方向伝搬を1度行い出力値を与える。

2.4 ケーススタディ

2.4.1 対象地域と使用データ

解析に用いた衛星データはLANDSAT/TMデータで、Path=109, Row=36に対して1987年11月11日に撮影されたものである。このデータから名古屋市の金山駅を中心とする約11 km×14 kmの範囲（400×512画素）を切り出し解析対象画像とした。解析対象領域の位置をFig. 2-4に示す。解析対象領域全域に対する学習データには、上

述の画像中から無作為に抽出した2000個の画素に対するスペクトルデータを用いた。この研究では、解析領域内のクラス別の画素数の偏りの影響を調べるため、領域を上下（南北）に二分し、上部を $a1$ 領域、下部を $a2$ 領域とした。このように、解析対象領域を南北に分割した理由は、南部において河川・港湾という水域が北部に比べて多くあり、クラス別画素の分布特性に大きな差があるためである。この2つの領域に対して、それぞれ1000個の教師データを無作為に抽出した。

教師データの作成には、空中写真を原情報とする10 mメッシュデータからなる細密数値情報の土地利用データを利用した。この土地利用データは、昭和49年から約5年周期でデータが更新されている。今回の解析ではTMデータの撮影日時に合わせて、昭和62年(1987年)のデータ(TDT-112)を用いた。

2.4.2 テストケース

本研究では、分類クラス数を6とした。Class 1からClass 6までのクラスと土地被覆状態との対応関係をTable 2-1に示す。

解析に用いた多段ネットワークは、TMデータのバンド数6（バンド6を除く）を入力ユニット数とする抽出ネットワークを分類クラス数に等しい6段並列し、その上に統合ネットワークを有する。中間層の層数などの抽出ネットワークのパラメータはTable 2-2に示される。抽出ネットワークに与える情報量（サンプル数）を全抽出ネットワークに対して等しくしていることから中間層ユニット数が全抽出ネットワークを通して同数になっている。また、学習回数を全抽出ネットワークで同数に設定してあるのは、全抽出ネットワークを並行して計算させ、統合ネットワークにおける待時間を短縮する効果を意図したものである。

以下に、前述した $a1$ と $a2$ の2つの領域についてそれぞれ6段の抽出ネットワークをもつ多段ネットワークを並列させ合計12段の抽出ネットワークによって学習させる解析（領域分割解析）と $a1$, $a2$ 両領域の教師データを一括して学習させる解析（全体領域解析）を行った結果を示す。

2.4.3 クラス分離特性

ニューラルネットワークの特徴であるクラス分離性について吟味するため、各クラスに対応する抽出ネットワーク個々について以下の検討を行った。 j クラスの判別に適した抽出ネットワークのバンド2から6用入力ユニットに対しては、 j クラスの教師データの各バンドスペクトルの平均値を与え、バンド1の入力ユニットには[0,255]の値を与え、そのクラス分離特性を調べた。

全体領域解析による出力結果をFig. 2-5(a)に示した。入力値が100以上ではクラス間

分離が明瞭であり、出力値は0もしくは1に分けられている。入力値が100以下においては複数の出力値が混在し20以下では分類が困難になっている。前述した領域分割解析のための多段ネットワークに対して同様の試行をした結果をFig. 2-5(b)に示す。この場合にはバンド1入力値が100以下においてもクラス間分離が明確になっている。解析対象領域を分割して多段化することにより、領域のもつクラス別の画素密度の違いによる影響を考慮できるものと考えられる。このため領域分割解析の方がより安定した分類が可能である。

Fig. 2-4の領域を解析した際のネットワーク出力値のうちA-A線上の画素についての値をFig. 2-6に示す。(a)は全体領域解析結果、(b)は領域分割解析結果である。この図からも多段化によるクラス間分離特性の向上が読み取れる。

2.4.4 推定の精度

分類精度の評価方法として以下の2通りが代表的である。

- ① 各分類クラスの生起確率と精度検証データにおける面積占有率の平均二乗誤差を精度評価指標とする。
- ② 分類結果と精度検証データの誤差マトリクス（判別効率マトリクス）の対角要素を精度評価指標とする。

①を適用するに際しては精度検証データの各分類クラスに対する生起確率が必要となる。したがって、①の適用は手法の汎用性を狭めると考え、本研究では②から精度を算出するものとする。特にここでは、E.J.Greenらによる分類確率の推定量²⁻¹⁰⁾を精度評価指標とする。

いま、カラム方向に実際のクラス、ロー方向に分類されたクラスをとる誤差マトリクスを考える。誤差マトリクスの成分を n_{ij} とすると、実際のクラスが j (A_j)、分類されたクラスが i (C_i)である際の条件付確率 $P(A_j | C_i)$ は次式で示される。

$$P(A_j | C_i) = n_{ij} / \sum_{j=1}^M n_{ij} \quad (2-13)$$

ここに、 M は設定クラス数である。したがって、Bayesの法則から $P(C_i | A_j)$ の推定量は、

$$\begin{aligned} P(C_i | A_j) &= P(A_j | C_i) \cdot P(C_i) / P(A_j) \\ &= \left(n_{ij} / \sum_{j=1}^M n_{ij} \right) / \left(\sum_{k=1}^M n_{kj} \left(n_{ij} / \sum_{j=1}^M n_{kj} \right) P(C_k) \right) \end{aligned} \quad (2-14)$$

で表される。以下ではとくに $P(C_i | A_j)$ を精度比較ための指標とする。教師データおよび教師データを含む解析対象領域全域について、全体領域解析結果の分類精度を検討した結果はTable 2-3に示される。表の値は式(2-14)により求めたものである。なお、同表下部には、誤差マトリクスの対角要素の平均値で表される総合精度 (Overall accuracy) および対角要素の標準偏差 (Standard deviation) を併記した。画素数の多いClass 4, 5に対して高い分類精度が得られている。これに対して、画素数の分布に領域的な偏りのあるClass 3については分類精度は低くなっている。

領域分割解析についてTable 2-3と同様の方法で分類精度を求めた結果をTable 2-4に示す。両領域についても多段化した解析結果ではClass 3に対する分類精度の向上がはかられており、各クラスに対応する画素数分布の領域特性を考慮した方が、より高精度の分類が行われることが見い出された。

2.4.5 従来法との比較

多段ニューラルネットワークによる解析結果を、統計的手法である最尤法およびニューラルネットワークと同様に学習データの分布形に依存しない手法であるファジー推論による解析例と比較し、本手法の有用性について考察する。

クラス分離特性を調べるために、バンド1に[0,255]を与える試行を、最尤法とファジー推論による方法に対して行った結果をそれぞれFig. 2-7, Fig. 2-8に示す。最尤法およびファジー推論による両方法ともに、各クラスの出力値は平均値を極値とする曲線分布となっており、その分離特性は不明瞭であり、クラス間の出力値の差もFig. 2-5に比較して小さい。

Fig. 2-6の場合と同様に、画像中の断面(A-A)について二つの方法で出力値を求めた結果をFig. 2-9およびFig. 2-10に示す。両図ともに、クラス間出力値の差が不明瞭であり、Fig. 2-6に示す多段ニューラルネットワークによる方が判定が容易であることが読みとれる。このことは、精度向上を目的とした補助的情報の選択に際して、Fig. 2-6における0出力画素を補完するデータを用意すればよいという結論を容易に与える。

Table 2-5およびTable 2-6は式(2-14)を用いて、それぞれ最尤法およびファジー推論による解析結果を表現したものである。表中マトリクスにおける殆どの要素に対して、多段解析結果が良好であり、教師データの学習能力だけでなく汎化能力に関してもその有用性が判断できる。

以上の検討より、多段ニューラルネットによる分類は他手法に比べ判定が容易であり、画素分布特性に偏りがある場合についても有効であることが示された。

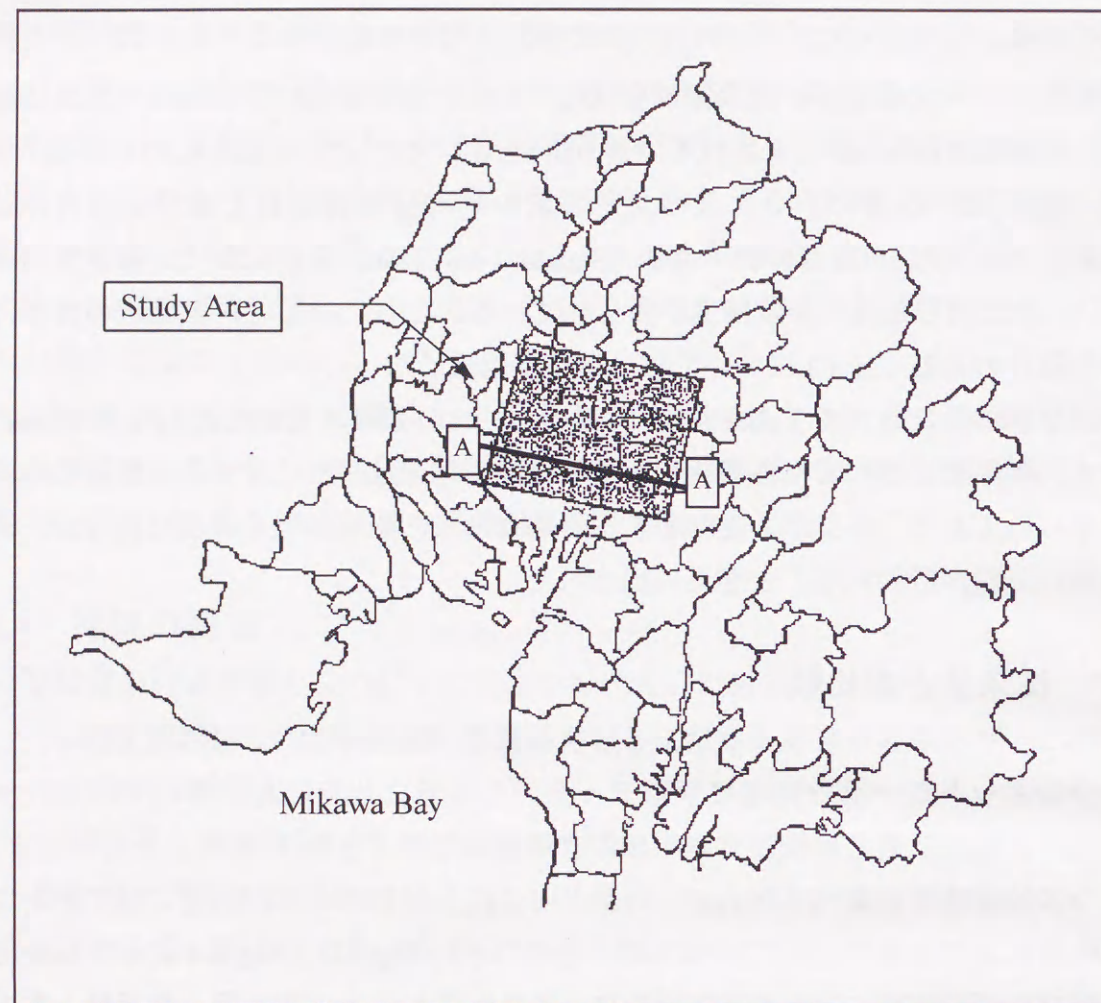



Fig. 2-4 Study area

Table 2-1 Classification categories and their actual surface conditions


Name of Class	Surface Condition	Number of Pixels of <i>a1</i>	Number of Pixels of <i>a2</i>
Class 1	Green	2716	1409
Class 2	Paddy Field	4034	4694
Class 3	Farm	1573	1111
Class 4	Residential Area	66523	71358
Class 5	Concrete Structure	26125	20188
Class 6	Water	1429	3640

Table 2-2 Neural network parameters used in this analysis

Parameter	Value
Number of Input Units	Number of Steps × Number of Bands
Number of Hidden Units	20
Number of Output Units	Number of Classes
Number of Training Patterns	2000 (Full Scene), 1000 (Half Scene)
Maximum Number of Iterations	1000




(a) Single-step analysis




(b) Multi-step analysis

Fig. 2-5 Difference of class separability of neural network



(a) Single-step analysis



(b) Multi-step analysis

Fig. 2-6 Neural network outputs of cross section (A-A)

Table 2-3 Estimates of likelihood for single-step NN analysis

CLASSIFIED CLASS	ACTUAL CLASS					
	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6
TRAINING DATA (2000 PIXELS)						
Class 1	0.672	0.024	0.111	0.007	0.000	0.042
Class 2	0.137	0.865	0.187	0.009	0.000	0.035
Class 3	0.032	0.000	0.632	0.001	0.000	0.033
Class 4	0.078	0.093	0.070	0.927	0.003	0.020
Class 5	0.044	0.017	0.000	0.051	0.985	0.135
Class 6	0.038	0.000	0.000	0.005	0.012	0.735
TEST DATA (204800 PIXELS)						
Class 1	0.629	0.083	0.174	0.010	0.005	0.033
Class 2	0.129	0.770	0.113	0.010	0.003	0.033
Class 3	0.049	0.035	0.512	0.003	0.000	0.007
Class 4	0.079	0.066	0.178	0.916	0.013	0.019
Class 5	0.001	0.045	0.014	0.055	0.966	0.152
Class 6	0.180	0.001	0.009	0.006	0.012	0.754

Overall accuracy : 0.803 (TRAINING DATA), 0.758 (TEST DATA)

Standard deviation : 0.144 (TRAINING DATA), 0.171 (TEST DATA)

Table 2-4 Estimates of likelihood for multi-step NN analysis

CLASSIFIED CLASS	ACTUAL CLASS					
	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6
TRAINING DATA (2000 PIXELS)						
Class 1	0.669	0.023	0.129	0.007	0.000	0.041
Class 2	0.128	0.893	0.158	0.007	0.000	0.012
Class 3	0.061	0.027	0.714	0.003	0.000	0.048
Class 4	0.053	0.039	0.000	0.950	0.038	0.035
Class 5	0.047	0.017	0.000	0.031	0.953	0.107
Class 6	0.041	0.000	0.000	0.002	0.009	0.758
TEST DATA (204800 PIXELS)						
Class 1	0.626	0.089	0.183	0.010	0.005	0.028
Class 2	0.145	0.732	0.108	0.006	0.001	0.006
Class 3	0.079	0.060	0.633	0.002	0.000	0.023
Class 4	0.036	0.079	0.045	0.946	0.034	0.044
Class 5	0.095	0.040	0.024	0.036	0.944	0.134
Class 6	0.019	0.001	0.007	0.001	0.016	0.765

Overall accuracy : 0.823 (TRAINING DATA), 0.774 (TEST DATA)

Standard deviation : 0.125 (TRAINING DATA), 0.143 (TEST DATA)




Fig. 2-7 Class separability of MLC analysis




Fig. 2-8 Class separability of Fuzzy analysis




Fig. 2-9 MLC outputs of cross section (A-A)




Fig. 2-10 Fuzzy outputs of cross section (A-A)

Table 2-5 Estimates of likelihood for MLC analysis

CLASSIFIED CLASS	ACTUAL CLASS					
	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6
TRAINING DATA (2000 PIXELS)						
Class 1	0.456	0.096	0.123	0.026	0.009	0.024
Class 2	0.128	0.899	0.192	0.023	0.002	0.047
Class 3	0.033	0.005	0.403	0.014	0.000	0.012
Class 4	0.000	0.000	0.000	0.856	0.106	0.000
Class 5	0.312	0.000	0.282	0.065	0.866	0.034
Class 6	0.072	0.000	0.000	0.015	0.017	0.833
TEST DATA (204800 PIXELS)						
Class 1	0.428	0.085	0.192	0.026	0.014	0.026
Class 2	0.212	0.827	0.187	0.021	0.002	0.012
Class 3	0.021	0.011	0.375	0.014	0.001	0.005
Class 4	0.013	0.018	0.009	0.852	0.115	0.011
Class 5	0.284	0.034	0.215	0.074	0.843	0.065
Class 6	0.042	0.025	0.022	0.013	0.025	0.881

Overall accuracy : 0.719(TRAINING DATA), 0.701(TEST DATA)
 Standard deviation : 0.226(TRAINING DATA), 0.233(TEST DATA)

Table 2-6 Estimates of likelihood for Fuzzy analysis

CLASSIFIED CLASS	ACTUAL CLASS					
	Class 1	Class 2	Class 3	Class 4	Class 5	Class 6
TRAINING DATA (2000 PIXELS)						
Class 1	0.630	0.019	0.105	0.024	0.001	0.030
Class 2	0.183	0.831	0.457	0.024	0.006	0.000
Class 3	0.039	0.032	0.439	0.013	0.000	0.018
Class 4	0.000	0.118	0.000	0.845	0.123	0.092
Class 5	0.096	0.000	0.000	0.082	0.843	0.116
Class 6	0.051	0.000	0.000	0.012	0.026	0.744
TEST DATA (204800 PIXELS)						
Class 1	0.575	0.029	0.083	0.026	0.008	0.024
Class 2	0.191	0.727	0.354	0.024	0.010	0.003
Class 3	0.051	0.039	0.451	0.013	0.000	0.010
Class 4	0.023	0.149	0.031	0.840	0.117	0.067
Class 5	0.129	0.030	0.056	0.091	0.829	0.056
Class 6	0.031	0.250	0.024	0.007	0.037	0.840

Overall accuracy : 0.722(TRAINING DATA), 0.710(TEST DATA)
 Standard deviation : 0.162(TRAINING DATA), 0.163(TEST DATA)






2.5 結語

本章により得られた結論は、以下のように整理できる。

- ① 多段ニューラルネットワークは、その段数を増すことで教師データの画素数の偏りに伴うクラス間重複画素の影響を軽減し、段数の少ないものよりも高精度で土地被覆分類が可能となる。
- ② 最尤法・ファジー推論による分類に対して多段ニューラルネットワークは、クラス間分離特性が優れる。すなわち、主題図作成時におけるクラスの割り当てに関して、唯一のクラスを選定するための判断が容易となる。
- ③ ニューラルネットワークのクラス分離を任意断面から判断すると、領域の境界と判断できる画素の出力値が小さいことが読み取れる。さらに分類精度を向上させるためには、このセグメンテーションなどにより領域境界を補完する情報を与える必要がある。
- ④ これらの検証は、理想的な教師データが存在するという前提で行われているので、災害によって教師データの信頼度に問題がある場合には、別の対処方法が望まれる。



Plate 2-1 TDT-112 image

Plate 2-2
Target imagePlate 2-3
Output of MLCPlate 2-4
Output of FuzzyPlate 2-5
Output of NN
(Conventional)Plate 2-6
Output of NN
(Proposed)

第3章 GTデータの不整を考慮した 土地被覆状態の推定方法

CHAPTER 3 LAND COVER CLASSIFICATION USING MULTISPECTRAL REMOTE SENSING DATA HAVING INCOMPLETE TRAINING DATA SETS

A method for classification of remotely sensed data having incomplete training data sets is introduced. To consider the time difference between training data sets and remote sensing data, the “causalities” based on Markov Random Field are utilized. By including the temporal class dependencies, the reliable classification is undertaken. It is expanded to a method evaluating the spatial class dependencies between neighboring pixels and the post processing. The performance of the method for land cover classification is investigated using LANDSAT/TM data covering Aichi Prefecture, Japan, and are compared with statistical data. The results show good agreement with the verification data. When post processing is carried out, the accuracy improves to a RMSE of about 1%.

KEY WORDS : Land Cover Classification, Markov Random Field, Causality, Ground, Truthing, Training Data Set

3.1 概説

本章では、被災直後において被災地全域の土地被覆状態を推定するためのグラウンドトゥールズ（GT）データの信頼性が不明確な場合において、過去の情報から推定される因果律より GT データに信頼度を与える方法についての一提案を行う。この方法論として、マルコフ確率場の概念を利用する。手法の検証は、細密数値情報土地利用データが整備されている名古屋市を対象領域としたケーススタディーにより行う。

3.2 GT データが不整を有する環境と問題点

衛星データの周期性、広域性および同時性等の利点を活かして、これより作成される主題図からその変化過程のモニタリングが可能となる。衛星データで構成される特徴ベクトルの多変量解析から主題図を作成する方法として、レベルスライス等の単純なもの、尤度関数に多次元正規分布を仮定する最尤法、さらに、人工知能を用いた処理法が挙げられる。それぞれの手法には方法論にしたがった利点・欠点が含まれ³⁻¹⁾、必要性に応じて処理方法を選択している。この中で、“理想的な環境”下で高精度分類を達成する手法の一つに、ニューラルネットワーク等の知的情報処理技術を用いた方法が挙げられる。ここで“理想的な環境”とは、任意の教師データにおけるクラス C_p での特徴ベクトル X_p およびクラス C_q での特徴ベクトル X_q がある範囲内で相互に重複しない場合、すなわち、

$$X_p \cap X_q = \phi \quad (3-1)$$

として定義できる。これを満足しない状態、すなわち、“理想的な環境”を与えない教師データを“不整を有した教師データ”として定義する。教師データが不整を有する場合、ニューラルネットワークでは極端な収束解が得られ、これに起因した誤分類の可能性が指摘されている³⁻²⁾。この誤分類は、統計的な出現率に基づいて教師データの中にも誤りが存在することを認める統計的手法の考え方に比して、ニューラルネットワークが全ての教師データが正解であることを前提とすることに起因する。

教師付き分類では、分類目的に応じたトゥールズデータや航空写真等の記録を用いて教師データを作成する必要がある。しかし、社会的な理由や地理的条件等によりこれらの入手が困難な場合も多い。また、観測条件が整っていても、対象時刻全てに対して完全に一致する教師データを作成することは困難である。さらに、広域な対象の分類に対し、全域から教師データを作成することも困難な場合が多い。教師データの

時間差やノイズ等による教師データの精度の劣化により、同一地域に対する処理結果を時系列で配列したときに、矛盾のある画素が出現することも少なくない。この問題に対処するために、誤抽出データの潜在およびサンプリングデータの多次元正規性を認め、これに従わないものを洗練・淘汰させる方法が提案されている^{3-3), 3-4), 3-5)}。この場合、平均値ベクトルが唯一として規定されるため、そのヒストグラムに多峰性のあるパターンに対して正解を与えることが困難となる。また、統計的な判断に基づき教師データを淘汰させることにより、必要な情報が削られる可能性も指摘できる。

以上の背景から、何らかの原因で不整のない教師データの構築が困難な場合に対して、①教師データとして与えられた情報を削除しないで、できるだけ“理想的な環境”を構築し、②“理想的な環境”下で最も精度の良いニューラルネットワーク^{3-6), 3-7), 3-8), 3-9)}を用いた分類スキームの構築が望まれる。この“理想的な環境”づくりを、マルコフ確率場^{3-10), 3-11)}に基づく因果律を与えることで実現する方法が以下に示される。

3.3 GT データの不整に対するマルコフ確率場の与え方

画像座標 (x, y) における K バンドの衛星データが構成する特徴ベクトルを $X(x, y) = \{x_1(x, y), \dots, x_K(x, y)\}$ で表す。土地被覆クラス $C(x, y)$ が L クラスの状態から構成されるとき、 $C(x, y)$ は $C \in \{C_1, \dots, C_L\}$ で表される。クラス C の特徴ベクトル X に対する確率密度（尤度）を $P(X|C)$ で表現するとき、分類問題は事後確率 $P(C|X)$ を最大にするクラスを求める問題に帰着する。ここで、Bayes の式により、特徴ベクトルと土地被覆クラスの関係を用いた事前確率が、

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)} \quad (3-2)$$

で与えられるので、 $P(C|X)$ を最大にする尤度関数、

$$\zeta(X|C) = P(X|C)P(C) \quad (3-3)$$

より、分類問題は $P(X|C)$ を最大とするクラスを求める問題に書き換えられる。 $P(X|C)$ の決定に対して、教師データの多次元正規性が確認されない対象に対しても適用可能なニューラルネットワークを用いることの有用性は先に示した通りである。ここで、 $P(X|C)$ は N 個の教師データのクラス $C = \{C^S | 1 \leq S \leq N\}$ とその特徴ベクトル $X = \{X^S | 1 \leq S \leq N\}$ の対 (C^S, X^S) の関係を用いて計算される。 C^S と X^S の作成における時刻差が (C^S, X^S) の関係に与える影響を考え、マルコフ確率場の考え方で、その

信頼度 $P(C^S | X^S)$ を求め、信頼度を考慮した教師データ対 $(P(C^S | X^S) \times C^S, X^S)$ が作成できる。さらに、この考え方は教師データの平面的な関係および分類結果のポスト処理に拡張することができる。

3.4 時系列での因果律の算定

マルコフ過程は、「状態空間」と「パラメータ空間」を事前に決定することで、変化パターンの一意的なモデル化が可能となる。「状態空間」として土地被覆クラス C を、「パラメータ空間」として時間軸 t をとり、時刻 t における土地被覆クラスを $C(t)$ ($\bar{C}(t) = \{C(q) | q \leq t\}$) を定義する³⁻¹²⁾。いま、Green と Titterton³⁻¹³⁾による仮定、

$$P(C(t) | \bar{C}(t-1)) = P(C(t) | C(t-1)) \quad (3-4)$$

を考える。ここに、式(3-4)はクラス設定に関する一次元定常マルコフ過程 (Fig. 3-1) における仮定と同値である。すなわち、この仮定を認める範囲内であれば土地被覆(利用)予測に関する確率過程モデルは、次式によって表現される³⁻¹⁴⁾。ただし、以下では表記が煩雑になることを避けるため、画像座標 (x, y) を省略して記載する。

$$C(0) = \begin{bmatrix} c_1(0) \\ \vdots \\ c_L(0) \end{bmatrix} \quad (3-5)$$

$$P = \begin{bmatrix} p_{11} & \cdots & p_{1L} \\ \vdots & p_{ij} & \vdots \\ p_{L1} & \cdots & p_{LL} \end{bmatrix} \quad (3-6)$$

$$C(t) = \begin{bmatrix} c_1(t) \\ \vdots \\ c_L(t) \end{bmatrix} \quad (3-7)$$

$$C(t) = PC(t-1) = \cdots = P^t C(0) \quad (3-8)$$

ここに、 $C(0)$ および $C(t)$ は、それぞれ基準時刻および時刻 t におけるクラス、 $\{c_1(t), \dots, c_L(t)\}$ はクラスの状態を示すパラメータを表す。例えば、時刻 t におけるクラスが明らかに C_1 のときは、 $\{c_1, c_2, \dots, c_L\} = \{1.0, 0.0, \dots, 0.0\}$ のように表すことができる。また、クラス P は推移確率行列である。状態数、すなわち、ここでいうクラスの数 L に設定するとき、 $P = \{p_{ij} | 1 \leq i \leq L, 1 \leq j \leq L\}$ は事前事象と事後事象との関係から構築される推移回数行列 $N = \{n_{ij} | 1 \leq i \leq L, 1 \leq j \leq L\}$ をその行和で除することにより与えられる。ただし、式(3-8)は推移パターンが時刻に依存しないという仮定を含む。時刻 t における状態確率を教師データの信頼度、すなわち、解析時の重みとして考えるとき、①日本のような開発国では、開発可能域が限定されることによって推移確率行列の対角要素が他に比較して極めて大きくなり、状態確率の変動がほとんど期待できない、②変化のトレンドだけを表現するため、変化が生じる構造を内包することができない、③常識的に考え難い変化パターンの存在を認める、等の問題が生じる。これらの問題に対処するために、時刻変化を含めた手法を提案した例も存在する³⁻¹⁵⁾。開発域と未開発域の大まかなカテゴリーを考え、都市が成長するときには、未開発域から開発域への変化が卓越する、すなわち、その可逆性をほぼ認めないものと仮定すれば、次式を推移確率に加えることで対処が可能となる。

$$\Delta P(t) = \begin{bmatrix} UU & UD \\ DU & DD \end{bmatrix} \quad (3-9)$$

ここに、 UU は未開発域から未開発域、 DD は開発域から開発域、 UD は未開発域から開発域、 DU は開発域から未開発域への変化率を示す。未開発域としては水域・森林・田畑等を、開発域としては宅地・商工業域を考えることができる。ここで、先述の理由により、 DU および DD は0であるとし、 UU の減少分が UD の増加分となるように推移確率を変動させる。ここで、 UD の増加分を規定する関係は都市に依存した関係となるので、過去の推移をベースに成長経路を判断し、 $UU = -UD = \eta$ とするパラメータを考える。 η は、都市の成長過程および残された開発可能領域の割合に依存する。最終的に、 $\Delta P(t)$ を含めた推移確率 $P'(t)$ を用いて、 T ステップ時刻差のある教師データ対に対して、

$$P(C^S | X^S) = \prod_{t=1}^T P'(t) \quad (3-10)$$

を与える。




Fig. 3-1 MRF probabilities for time-series data




Fig. 3-2 MRF probabilities for data distribution




Fig. 3-3 MRF probabilities for post processing

3.5 平面的な因果律の算定

時系列での因果律から、基準時刻からの時間差による教師データのクラスごとの重みを変化させることは可能となる。しかし、解析対象とする画像のどの地点が問題となるのかの判断が困難であることには変わりない。福江ら³⁻¹⁶⁾は周辺画素を含めた同時生起確率を入力とするニューラルネットワークを構築し、高精度の判別結果を得ている。この研究は、ラスタ走査で対象とする画素および周辺画素に対する出現率を取り扱うものである。

ここでは、1次元のマルコフ過程を2次元に拡張し、周辺画素の着目画素（中心画素）に対する因果律を推移確率により定める。2次元の情報系列にマルコフ過程を適用するには、1次元の処理における時刻 t と時刻 $t + \Delta t$ の関係をラスタ走査によって与えられる順序と考え、走査順にしたがった因果律を与える³⁻¹⁷⁾。そこで、Fig. 3-2に示されるように、事前事象を着目画素と近隣画素（縦・横・斜めの計8方向、ただし、Fig. 3-2では斜め4方向のみを表示）との衛星データの差分 $\Delta\xi$ 、事後事象を近隣画素とさらにその同方向近隣画素（8方向）との衛星データの差分 $\Delta\xi'$ とし、それぞれの方向の $\Delta\xi - \Delta\xi'$ の平方和をバンド数だけ加算した平方根、すなわち、平方根平均自乗誤差（RMSE）を計算し、閾値を設定して離散化し、推移確率を定める。

3.6 ポスト処理への拡張

$\bar{X}(t) = \{X(q) | q \leq t\}$ および $\bar{C}(t) = \{C(q) | q \leq t\}$ とおくと、条件付き確率 $P(\bar{C}(t) | \bar{X}(t))$ は次式のように示される。

$$P(\bar{C}(t) | \bar{X}(t)) = \frac{P(\bar{C}(t) \cap \bar{X}(t))}{P(\bar{X}(t))} \quad (3-11)$$

上式は、存在する衛星データを過去から順に加算していくことで計算できる。ここで、Green と Titterton による式(3-4)の仮定と、ノイズやクラス設定に関する時間的な依存性に関する仮定、

$$P(X(t) | \bar{C}(t) \cap \bar{X}(t-1)) \equiv P(X(t) | C(t)) \quad (3-12)$$

より、

$$P(X(t) | \bar{C}(t)) = P(X(t) | C(t))$$

$$P(\bar{X}(t) | \bar{C}(t)) = \prod_{r=1}^t P(X(r) | C(r))$$

$$P(\bar{C}(t) \cap \bar{X}(t)) = P(\bar{X}(t) | \bar{C}(t)) \cdot P(\bar{C}(t))$$

$$\begin{aligned} P(\bar{C}(t)) &= \frac{P(\bar{C}(t))}{P(\bar{C}(t-1))} \cdot \frac{P(\bar{C}(t-1))}{P(\bar{C}(t-2))} \cdots \frac{P(\bar{C}(1))}{P(\bar{C}(0))} \cdot P(C(0)) \\ &= P(C(t) | \bar{C}(t-1)) \cdot P(C(t-1) | \bar{C}(t-2)) \cdots P(C(1) | \bar{C}(0)) \cdot P(C(0)) \end{aligned} \quad (3-13)$$

を用いて,

$$P(\bar{X}(t) \cap \bar{C}(t)) = \left(\prod_{r=1}^t P(X(r) | C(r)) P(C(r) | C(r-1)) \right) P(C(0)) \quad (3-14)$$

が導かれる。したがって、対象とする時刻までの特徴ベクトル $\bar{X}(t)$ と $\bar{C}(t-1)$ を条件とする $C(t)$ の生起確率は以下のように計算される。

$$\begin{aligned} P(C(t) | \bar{C}(t-1) \cap \bar{X}(t)) &= \frac{P(\bar{C}(t) \cap \bar{X}(t))}{P(\bar{C}(t-1) \cap \bar{X}(t))} \\ &= \lambda P(C(t) | C(t-1)) P(X(t) | C(t)) \end{aligned} \quad (3-15)$$

ここに、 λ は比例定数である。 $P(C(t) | C(t-1))$ を Fig. 3-3 に示されるように、事前事象を時刻 $t-1$ での周辺画素のクラス、事後事象を時刻 t での着目画素のクラスとして求める。教師データから得られる $P(X(t) | C(t))$ から、最終的に $P(C(t) | \bar{C}(t-1) \cap \bar{X}(t))$ を得る。

$P(C(t) | \bar{C}(t-1) \cap \bar{X}(t))$ を用いて、前節までの分類結果で得られた土地被覆変化が、信頼できるか否かを以下のような基準で判断する。

- ① クラスごとに得られる $P(C(t) | \bar{C}(t-1) \cap \bar{X}(t))$ を、周辺画素（8方向）に対して計算し、その和 P_{TOTAL} を計算する。
- ② P_{TOTAL} の最大値をもつクラス C について、その P_{TOTAL} が、設定する閾値よりも大きい場合はその推移の生じる可能性があるとして判断し、時刻 t の解析結果が妥当であるとする。
- ③ P_{TOTAL} の最大値をもつクラス C について、その P_{TOTAL} が、設定する閾値以下である場合には、その推移パターンはあり得ないものであるとし、時刻 $t-1$ の解析結果を採用する。

3.7 ケーススタディー

3.7.1 対象地域と使用データ

解析対象は、データの整備状況を考慮し名古屋市（第2章のケーススタディーと同一地域）とした。対象地域には、約 10m の解像度で、1982 年、1987 年および 1993 年に細密数値情報土地利用データ（それぞれ、TDT-111, TDT-112 および TDT-113, 以下 TDT データとして略記する）が作成されている³⁻¹⁸⁾。この中から、衛星データとして用いる LANDSAT/TM データ（Path=109, Row=36）の撮影時刻に合わせて、1987 年を基準時刻とし、これらのデータ対より作成される情報を用いて、1991 年および 1995 年の TM データから土地被覆分類画像を作成する場合の精度評価を行った。ここに、教師データは TDT-112 を参照して土地被覆と土地利用の定義が共通する画素を各カテゴリで 200 画素ずつ計 1000 画素抽出した。設定した土地被覆カテゴリは、水域（WATER）、森林等緑被域（FOREST）、田畑（PADDY）、住宅域（RESIDENT）、商工業地域等高密度開発域（IND&COM）とした。ここで、TDT データから推移確率算定に利用したカテゴリの変換方法を Table 3-1 に示す。

3.7.2 解析に用いたニューラルネットワーク構造

解析に用いたニューラルネットワークは、バックプロパゲーション学習原理に基づく 3 層・完全層間結合³⁻²⁾のものである。これらの諸パラメータを Table 3-2 に示す。

3.7.3 テストケース

基準時刻（1987 年）の教師データ対から、1991 年および 1993 年の土地被覆分類を、以下に示す 6 ケースを設定して行った。

- ① CASE 1: 基準時刻における教師データを全時刻の TM データに適用する（合計パターン：1000）。
- ② CASE 2: 基準時刻における教師データを TM データの ISODATA クラスタリングによりグループ分けを行い、同一グループと判断できない教師データを洗練・淘汰させ、全時刻の TM データに適用する（合計パターン：577）。
- ③ CASE 3: 各時刻における教師データを TM データの ISODATA クラスタリングによりグループ分けを行い、同一グループと判断できない教師データを洗練・淘汰させ、各時刻の TM データに適用する（合計パターン：577（1987 年）、522（1991 年）、618（1995 年））。
- ④ CASE 4: 時系列での推移確率から、各時刻の教師データの重み（状態確率）を求め、各時刻の TM データに適用する（合計パターン：1000）。

- ⑤ CASE 5: 平面的な推移確率から, 各画素の教師データの重み (状態確率) を求め, 各時刻の TM データに適用する (合計パターン: 1000) .
- ⑥ CASE 6: CASE 4 と CASE 5 を併用する (合計パターン: 1000) .

Table 3-1 TDT data and Categories used in this analysis

TDT Category	C	TDT Category	C
1 : Forest	2	9 : Residential Area (3)	-
2 : Paddy field	3	10 : Commercial Area	5
3 : Farm	3	11 : Roads	-
4 : Under Construction	-	12 : Parks	-
5 : Vacant Land	-	13 : Public Facilities	-
6 : Industrial Area	5	14 : Rivers and Lakes	1
7 : Residential Area (1)	4	15 : Others	-
8 : Residential Area (2)	4	16 : Sea	1

C : Land Cover Category : 1:WATER, 2:FOREST, 3:PADDY, 4:RESIDENTIAL AREA, 5:IND&COM

Table 3-2 Neural network parameters used in this analysis

Parameter	Value
Number of Input Units	Number of Steps × Number of Bands
Number of Hidden Units	20
Number of Output Units	Number of Classes
Number of Training Patterns	10000
Maximum Number of Iterations	1000*

(*) depend on the CASE




Fig. 3-4 Time-series change of residential area occupation ratio

3.7.4 推移確率行列の算定結果

Fig. 3-4 は土地利用台帳に記載される, 愛知県全域, 名古屋市の開発域 (地目: 宅地) 面積の全域面積に占める割合を示したものである. このような短い期間内では, 都市の成長速度はほぼ線形と考えることができる. この関係をパラメータとし, $\eta = -0.01$ とした場合, TDT-111 と TDT-112 との関係から得られる推移確率に基づく状態確率は Fig. 3-5 のように示される. 図の横軸は, 基準時刻 (1987 年) からの時間をとってあり, 推移のステップは 1 年としている. ただし, TDT-111 と TDT-112 の間隔は 5 年であるため, この間の推移が定常的であるとして 1 年間隔のデータを推計している. Fig. 3-5 に示されるように, 事前事象が開発域である場合, 事後事象も同事象である可能性が高く評価されている. 水域, 森林域および田畑は, 埋め立てや開発に伴う開発域への変化を妥当に評価している. 各状態確率の変動において水域に変動がみられるのは, 埋め立てによる推移パターンを推移確率の算定に含めたためである.

Fig. 3-6 は, 平面的な因果律を示す状態確率を示したものである. Fig. 3-6 の横軸は, 着目地点からの距離 (画素数) をとってある. $\Delta\epsilon$ および $\Delta\epsilon'$ の閾値は共に 20 ごとに設定してある. 推移確率の算定に用いた RMSE の事前事象が 20 未満の場合, 事後事象が 20 以上であることは希であることがわかる. 事前事象が 20 以上である場合は, すべての事後事象が生じる確率がほぼ等しいことがわかる. すなわち, 事前事象が 20 未満程度であれば教師データの信頼度を高くとることができる.

Fig. 3-7 は, ポスト処理に用いる状態確率, すなわち, 基準時刻におけるクラスが任意時刻 Δt 後に任意の被覆クラスになる確率を示したものである. Fig. 3-7 の横軸は, 基準時刻 (1987 年) からの時間をとってあり, 推移のステップは 1 年としている. この状態確率の変化はある年 (基準年から 20 年程度) で収束する. すなわち, ポスト処理は収束する年までは事前事象を基準とした多数決フィルタの役割をもつと考えられる.

3.7.5 学習収束に関する安定性評価

学習収束の速度を見るために, Fig. 3-8 に学習収束曲線を示した. 同図は, 縦軸に誤差を横軸に学習回数をとっている. 1987 年を基準時刻としているため, 1987 年における CASE 1 と CASE 4, CASE 2 と CASE 3 および CASE 5 と CASE 6 は同値となる. CASE 3 の誤差が低く現れているのは, ISODATA クラスタリングによって同一グループ内に複数のカテゴリーが混在する場合, そのデータを教師データから削除しているためである. しかし, CASE 2 と同じ方法で時刻差を含む CASE 3 においては誤差が大きく現れる. このことから CASE 2 が対象時刻のみに対して一見都合の良さそうな判断をするだけであると推察される.

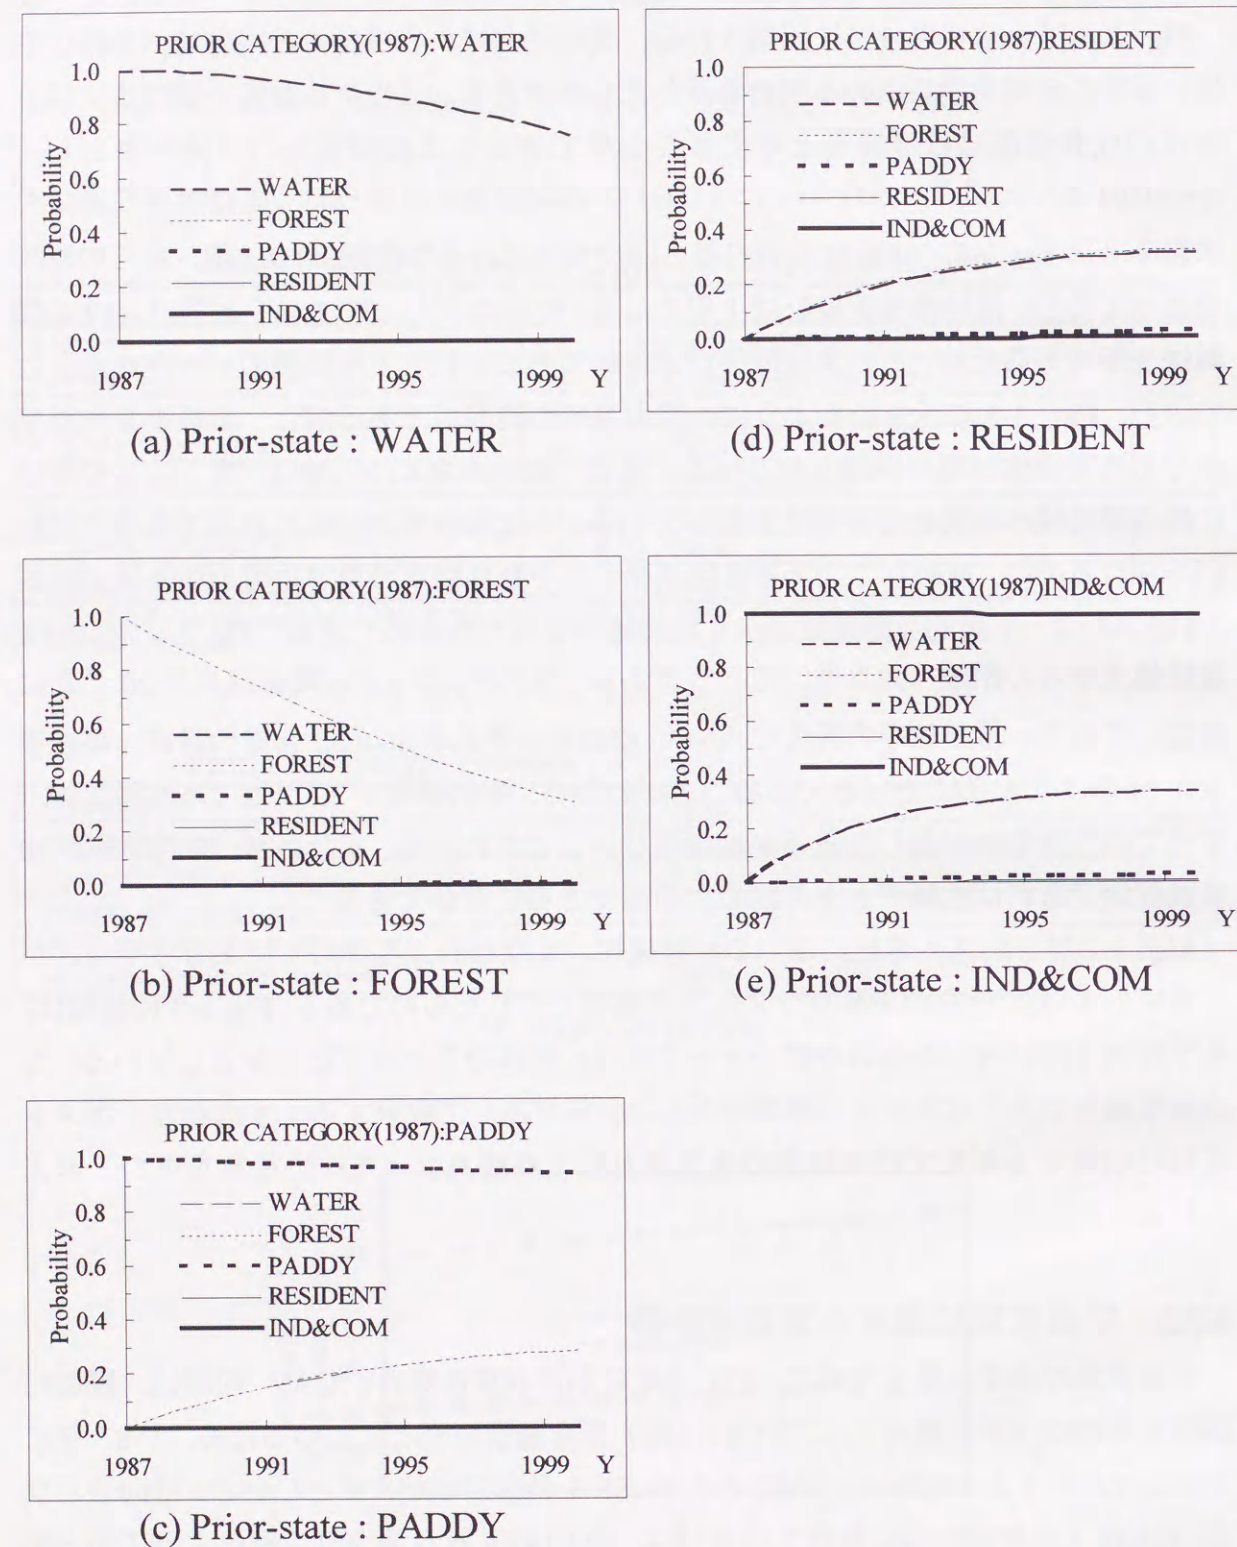


Fig. 3-5 State probabilities based on the time-series relationship




Fig. 3-6 State probabilities based on the data distribution

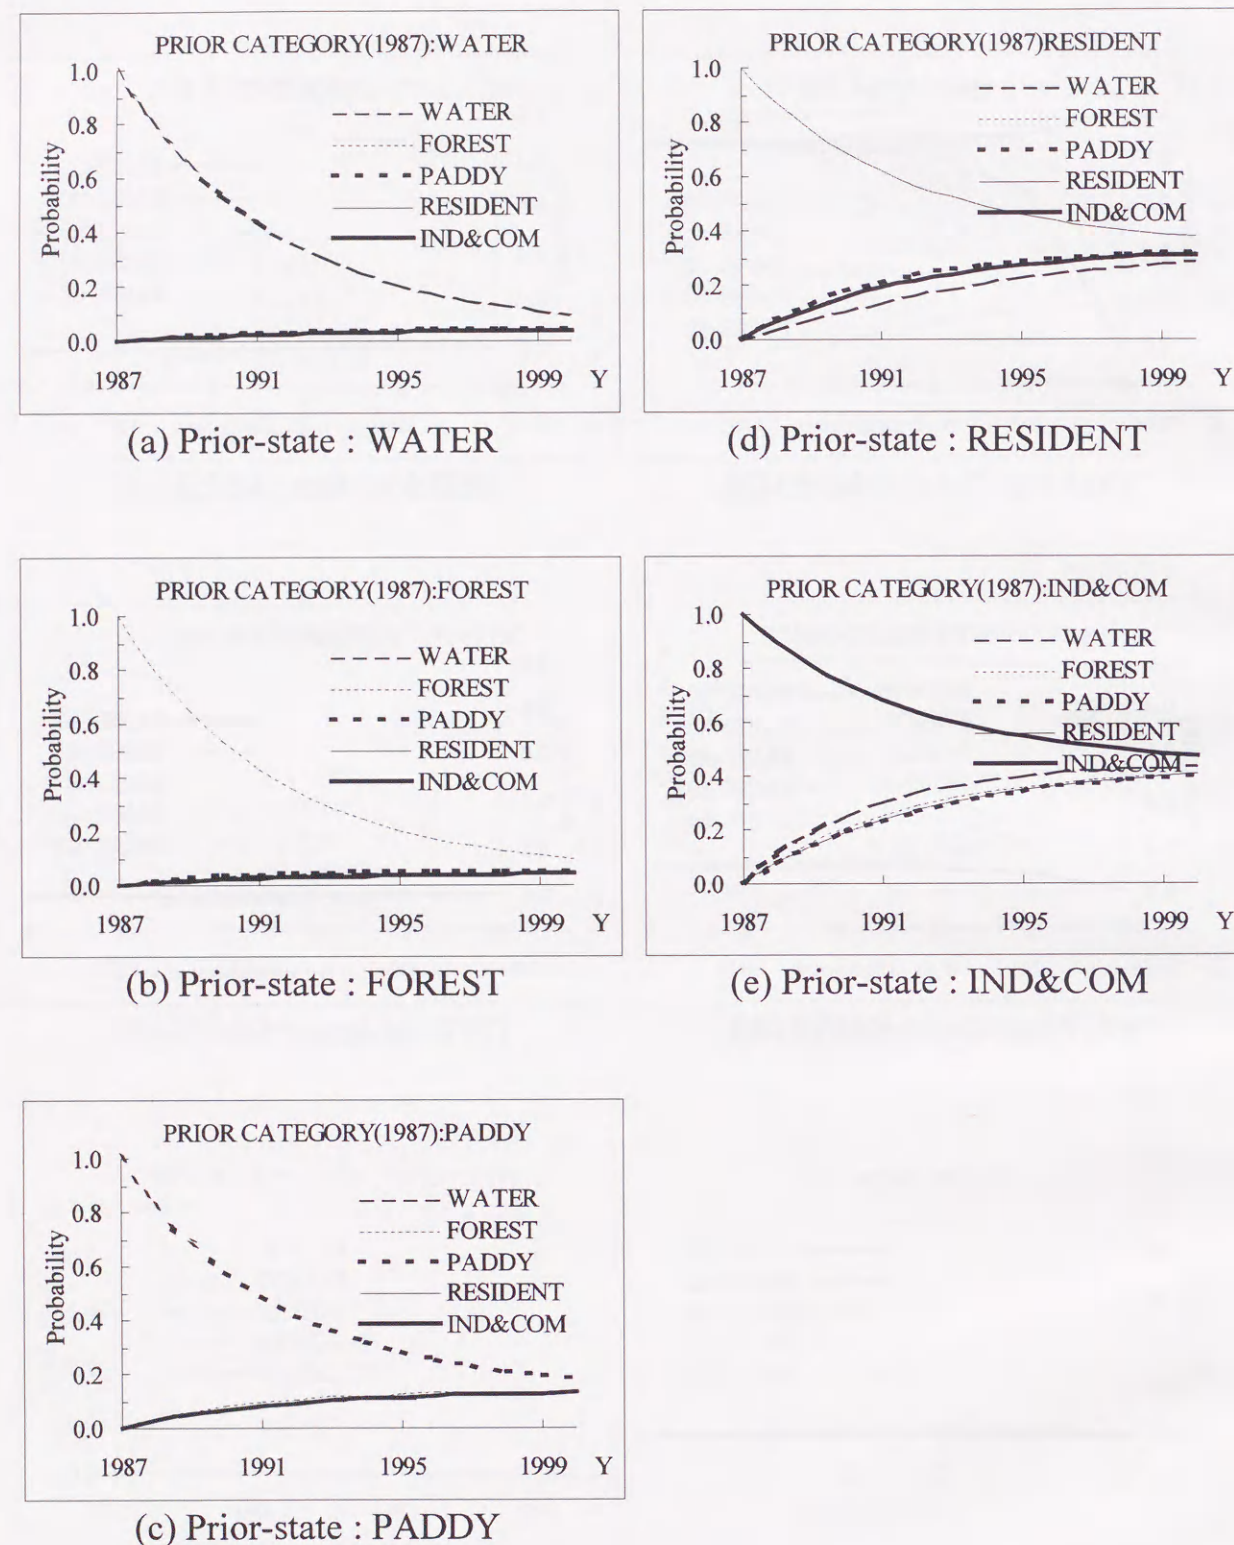


Fig. 3-7 State probabilities for post processing

結果を総合的に判断すると、因果律を与える方法 (CASE 4, CASE 5, CASE 6) が原データを用いる方法に比較して早期に安定して収束状態に入っていることがわかる。

3.7.6 処理の安定性

Fig. 3-9 は、宅地 (RESIDENT) の面積の全域に対する占有率の時系列変化を出力したものである。ここに、CASE 2 の基準時刻における結果は、CASE 3 と同値となる。また、CASE 6 の基準時刻における結果は、CASE 4 と同値となる。ただし、CASE 4 の基準時刻における結果は、CASE 5 の値を用いている。解析に用いた 1991 年の TM データは、平均値および分散が他と明らかに異なるものであった。


これらの結果より、1987 年のデータを信頼する CASE 1, CASE 2 および CASE 3 における時系列での評価に矛盾、すなわち、考え難い面積占有率の増減が認められる。これに対し、提示手法、とくに CASE 5 は、多少の変曲点は存在するものの、処理に対する安定性が確認できる。CASE 5 の結果が良好であることは、全く同時刻の教師データに対しても、センサーの状態や標本化する際の境界により信頼度が異なることを意味する。

Fig. 3-9 において○の一点鎖線で示される変化は、Fig. 3-4 で示した土地利用台帳の値をプロットしたものである。同様に、○の二点鎖線で示される変化は、Fig. 3-4 で示した土地利用台帳の値と比較するために、CASE 6 に関する宅地面積の水域 (WATER) を除いた全面積に対する占有率をプロットしたものである。これらの対応関係は、提示手法の有用性を示している。


Fig. 3-4 で示される宅地面積の拡大速度がほぼ線形であることより、1987 年から 1991 年および 1991 年から 1995 年の各カテゴリーの占有面積の変化率が一定であるとして両時刻間での微分値の差の絶対値をとり、カテゴリー数だけ合計したものを解析精度評価の指標値とした。この結果を Fig. 3-11 に示す。これより、時系列での因果律を考える CASE 4 および平面的な因果律を考える CASE 5、さらに両者を併用する CASE 6 の効果が確認できる。

3.7.7 ポスト処理の効果


Fig. 3-10 は、Fig. 3-9 と同じ方法で、ポスト処理を施した結果 (CASE 番号に P を付す) を出力したものである。ただし、ポスト処理に用いるパラメータ λ は 1.0 とし、 P_{TOTAL} の閾値は周辺 8 画素の合計で 4.0 とした。すなわち、各画素の平均の出現率が 0.5 以下の場合、その変化があり得ないものとして判断した。



(a) applied to TM data, 1987



(b) applied to TM data, 1991



(c) applied to TM data, 1995

Fig. 3-8 Learning convergence curve




Fig. 3-9 Time-series change of RESIDENT in Nagoya city without post processing




Fig. 3-10 Time-series change of RESIDENT in Nagoya city with post processing




Fig. 3-11 Accuracy for Nagoya analysis without post processing




Fig. 3-12 Accuracy for Nagoya analysis with post processing

対象地域では、埋め立てによって水域が、宅地等への開発によって植生域および田畑が減少する傾向にある。因果律を考える CASE 4, CASE 5, CASE 6 はこれらを適切に表現している。また、両時刻間の微分値も安定しているため、Fig. 3-11 と同じ方法で出力した RMSE は Fig. 3-12 に示されるように極めて 0 に近くなっており、その有用性を示している。

3.7.8 処理の汎用性

手法の汎用性を議論するとき、①状態確率（推移確率）の汎用性と②未知入力パターンに対する汎用性（汎化能力）の二点を考慮する必要がある。

まず、状態確率の汎用性を検討する。解析対象とした名古屋市の宅地域の拡大は、Fig. 3-4 に示されるように線形に近いものであり、基準時刻を時間軸の原点にとれば、愛知県全域のデータに対して切片が約 40% 大きく現れる。これによって、一見状態確率の変動が異なるように判断される。しかし、Fig. 3-13 および Fig. 3-14 に示されるように、非定常定数 η の導入により、既開発域の割合は状態確率の変動にほとんど影響を与えない。すなわち、開発形態がこれまでと同様であれば、先に得られた状態確率に汎用性があるといえる。

つぎに、未知学習パターンに対する汎化能力についての検討を行う。これに当たって、先述の解析に用いたデータを同時刻（1991 年および 1995 年）の愛知県全域を含むフルシーンを解析した。Fig. 3-9 から Fig. 3-12 と同様の方法で、フルシーンを解析した結果を Fig. 3-15 から Fig. 3-18 に示す。以上より、精度の判断材料となる標準偏差が小さいこと、統計資料と解析結果の傾きが近似することから判断して、汎化能力が確保できているものと考ええる。とくに、ポスト処理の効果が大きいことが特筆すべき点である。

3.8 結語

本章によって得られた結論は、以下のように整理できる。

- ① 時系列的な推移、2 次元平面上での空間的な推移、さらに処理後の事象発生確率をマルコフ確率場に与え、教師データの信頼度を表現すれば安定した土地被覆分類図を作成することが可能となる。
- ② ①で得られる推移確率行列は、TM データのフルシーン程度であれば汎用性が確保される。
- ③ 提示方法は、基準時刻における衛星データと実際の状態を示す地図があれば時間差やノイズの影響をある程度低減できるものである。逆から考えれば、基準時刻

におけるデータ対が整うことが必要条件となる。ただし、本手法は常識的に考えられる被覆変化を想定しているため、これに従わない場合の汎用性については定かではない。被災地域全域の概略的な把握を行う場合、被災前後の被覆状態の推移が常識的に考え難いノイズとして捉えられることから、災害域での構造的推移をある程度組み入れる必要がある。

- ④ 提示手法は、ニューラルネットワークへ与えるだけでなく他の手法への適用性に関しても検討する必要がある。
- ⑤ ポスト処理の効果が大きかった結果から、マルコフ確率場のみから判断する方法についても検討の余地がある。




Fig. 3-13 State-probability change for each category in Nagoya city without post processing in case of target category equals to 1.0




Fig. 3-14 State-probability change of RESIDENT for full scene without post processing in case of target category equals to 1.0




Fig. 3-15 Time-series change of RESIDENT for full scene without post processing




Fig. 3-16 Time-series change of RESIDENT for full scene without post processing




Fig. 3-17 Accuracy for full scene analysis without post processing




Fig. 3-18 Accuracy for full scene analysis with post processing




(a) TDT-112 (1987)



(b) TDT-113 (1993)

Plate 3-1 Detail land use information image (after converted)


Blue: CATEGORY 1, Green: CATEGORY 2, Yellow: CATEGORY 3, Gray: CATEGORY 4, Red: CATEGORY 5, Black: OTHERS



(a) CASE 1

(a) CASE 1

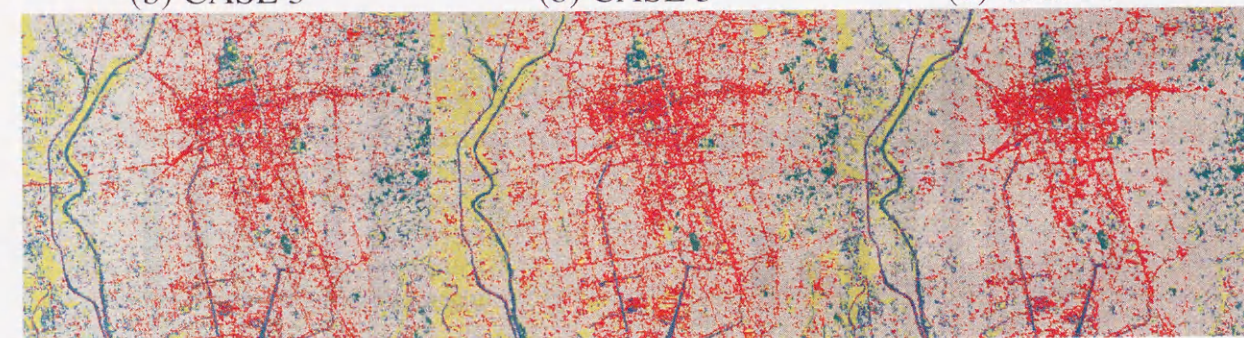
(a) CASE 1



(b) CASE 3

(b) CASE 3

(b) CASE 3



(c) CASE 6

(c) CASE 6

(c) CASE 6

Plate 3-2
Results for 1987 data**Plate 3-3**
Results for 1991 data
without post-processing**Plate 3-4**
Results for 1991 data
with post-processing

第4章 VNIRデータを用いた 地形変化の検出方法

CHAPTER 4 DETECTION OF TOPOGRAPHICAL CHANGE USING VNIR DATA

A new method to detect topographical changes using Mathematical Morphology algorithm is introduced. Conventional morphological edge detectors can detect edge information clearly. Their outputs, however, show different gradients depending on the formula and the size of structuring element.

From this point of view, a multiplex Wide-Narrow morphological Edge Detector (WNED) is introduced. WNED consists of wide range edge detection (WED), narrow range edge detection (NED) and their subtraction. Performance of WNED is shown by applying Visible and Near IR images of LANDSAT/TM data which cover Shonai river and Kiso river in Japan and are compared with the results analyzed by conventional formulae. As the results of the case study, the following are found. Application of conventional edge detectors is not sufficient to pick up the weak gradients. Even if the size of structuring element for conventional ones is increased, undesirable gradients are detected. In contrast to such algorithms, WEND can detect the desired gradients and can delete the spurious edge pixels by subtracting NED gradients from WED gradients.

KEY WORDS : Topographic Change, Edge Detection, Gradient, Segmentation, Filtering, Mathematical Morphology

4.1 概説

本章では、被災域における規則性のある地形の変化検出を目的とした衛星データの境界変化検出手法についての一提案を行う。この方法論として、構成要素と呼ばれるフィルタの形状を利用して構成要素で表現可能な対象画像の形状を処理に反映させることができる Mathematical Morphology (以下, Morphology で略記する) の概念を利用する。手法の検証は、細密数値情報土地利用データが整備されている名古屋市を対象領域としたケーススタディーにり行う。

4.2 被覆状態の把握における境界検出の有効性と Morphology の効果

地域防災における衛星データの役割は、地表の状態を広域に、また時系列で与えることである。このような地盤や河川、都市防災等の地表状態に関する情報は、デジタルデータとして与えられ、センサーに応じた処理を通して様々なかたちで主題図が作成される。その処理の多くは分類問題として構築される。セグメンテーションの観点からは、液状化等の面的な区域抽出に対する領域生成問題、および河川幅員の推定等を行うための線成分抽出に対する境界検出問題に分類される。前者は、多次元画像の多変量解析として行われることが多いが、衛星データには複数クラスの混在画素が存在し、各バンドの輝度値から構成される特徴空間の分割だけで処理を行うことは困難といえる。とくに、領域と領域の境界 (edge) は複数クラスの混在画素の線状集合と考えられ、領域分割の精度を悪化させる大きな要因と成り得る。逆に解釈すれば、境界検出によって得られる情報は、別の処理の精度向上に有用な付加情報と成り得る。

これまで、境界検出問題は Laplacian に代表される空間微分の畳み込み演算を用いることが多く見られた。これらの従来手法は任意の対象物に対して、平均的に良好な結果を出力するが画像中の雑音を鋭敏に検出するため不適当な場合があるとされる。これに対し、対象物の規則性を利用することにより、より精度良く処理結果を与えることができる。Morphology は、構成要素と呼ばれるフィルタの形状を利用して構成要素で表現可能な対象画像の形状を処理に反映させることができる⁴⁻¹⁾。

Morphology は与えられた 2 値画像、あるいは濃淡画像からの特徴検出を主たる目的とし、集合論的操作からなる画像の変換手法に関する一貫した数学的な理論体系である^{4-2), 4-3)}。この手法は、従来より用いられてきた信号処理よりも物体の形状や欠損部分を特徴づけるのに適している。一般的なフィルタリングにおけるフィルタ (オペレータ) に相当する Morphology の構成要素が、直接的に物体の形状を捉えることができるためである。先験情報として形状が得られる場合に対しては、とくに能力が発揮

される。地理情報は都市の規模や都市の生成過程等に応じて土地被覆の状態は異なるが、基本的な自然地形のパターンを特定することはできる。衛星データより得られる地理情報すなわち被覆画像は、自然地形の地理学的背景に人工的な開発がもたらした構造物が存在する合成画像と考えることができる。Morphology は、このような合成画像から規則性のある単一の画像に分解することも可能となる⁴⁻⁴⁾。

上述の背景から、以下では規則性に関する Morphology の利点を活用し、河川のように衛星データの輝度値が任意の基点 (陸域) から対岸方向に河川幅だけ変化し、再び基点に閉じるまでの区間における境界 (水際線) の検出を行う方法について示す。この対象に対する Morphology 処理を実現するための検討項目として、基本演算の組み合わせの検討と構成要素の構造の検討が挙げられるが、ここでは、Morphology 基本演算の組み合わせに着目する。とくに、従来より検討されてきた基本演算の組み合わせを更に多重化した式の効果について紹介される。

4.3 Morphology 演算

4.3.1 Morphology の種類

Morphology における集合は、2 値あるいは濃淡で表された形状を表す。2 値の Morphology は、ユークリッド空間上において選択された点の集合とその補集合により構成される。これに対し、ユークリッド空間上の関数を画像の濃淡を表すものと考えられる場合、これを濃淡 (多値) あるいはグレースケール Morphology という。本研究で取り扱うデータは関数 (濃淡) であることから、原画像を $f(x)$ で、構成要素を $k(x)$ で表現する。ここに、 x は画像次元を示す独立変数である。

4.3.2 陰影変換と表面変換

N 次元ユークリッド空間 E^N 上の関数を画像の濃淡を表すものと考えたとき、これを濃淡画像 (Gray-tone Function) と呼ぶ。ここで、 E^N 上の濃淡画像 $f(x)$ に対し、 $F \subseteq E^{N-1}$ および $f: F \rightarrow E$ とするとき、その陰影変換 (Umbra Transformation) は次式で定義される⁴⁻¹⁾。

$$U[f](x) = \{(x, y) \in F \times E \mid y \leq f(x)\} \quad (4-1)$$

特に、 x が $f(x)$ の定義域にないとき $U[f] = -\infty$ となる。ここに、 $y = F(x)$ 、 x は $(N-1)$ 次元ベクトルである。

陰影の最上部 (表面) は表面変換によって次式で定義される。

$$T[U(f)](x) = \max\{y \mid (x, y) \in F \times E\} \quad (4-2)$$

したがって、 $T[U(f)](x)$ は $f(x)$ の定義域内における最大値を示す。

4.3.3 基本演算

濃淡画像 $f(x)$ に対する構成要素 $k(x)$ の Morphology 基本演算は以下のように表される。

$F, K \subseteq E^{N-1}$ において、 $f: F \rightarrow E$ 、かつ $k: K \rightarrow E$ とするとき、dilation ($d(x)$) は Minkowski 和 ($(f \oplus k)(x)$) を用いて次式で定義される。

$$\begin{aligned} d(x) &= (f \oplus k)(x) \\ &= T[U(f \oplus k)](x) \\ &= T[U(f) \oplus U(k)](x) \\ &= \max_{z \in K, x-z \in F} \{f(x-z) + k(z)\} \end{aligned} \quad (4-3)$$

dilation と同様の条件において、陰影変換画像の Minkowski 差は空集合となるが、 $f(x)$ の双対性を利用して $-f(x)$ を定義することにより、erosion ($e(x)$) は次式のように一旦 dilation に変形することで矛盾なく定義される。

$$\begin{aligned} e(x) &= (f \otimes k)(x) \\ &= -((-f) \oplus \hat{k})(x) \\ &= -T[U((-f) \oplus \hat{k})](x) \\ &= -T[U(-f) \oplus U(\hat{k})](x) \\ &= -\max_{z \in K, x-z \in F} \{-f(x-z) + \hat{k}(z)\} \\ &= \min_{z \in K, x+z \in F} \{f(x+z) - k(z)\} \end{aligned} \quad (4-4)$$

ここに、 $\hat{k}(x)$ は $k(x)$ の反射 ($\hat{k}(x) = k(-x)$) である。

以上を用いて、opening ($o(x)$) および closing ($c(x)$) は以下のように定義される。

$$o(x) = (f \circ k)(x) = ((f \otimes k) \oplus k)(x) \quad (4-5)$$

$$\begin{aligned} c(x) &= (f \bullet k)(x) \\ &= ((f \oplus k) \otimes k)(x) \\ &= ((-(-f) \otimes \hat{k}) \otimes k)(x) \\ &= (-((-f) \otimes \hat{k}) \oplus \hat{k})(x) \\ &= (-(-f) \circ \hat{k})(x) \end{aligned} \quad (4-6)$$

4.3.4 Morphology 的フィルタリング

Morphology は一般的に N 次元ユークリッド空間で定義されるが 2 次元画像解析においては 2 次元平面上の 2 項演算となる。Morphology 演算は基本的には集合演算であるが、上述のように陰影変換を用いることにより関数にも拡張される^{4-2), 4-3)}。

Morphology における 2 次元画像のフィルタリングは、入力画像と構成要素が集合 (2 値) か関数 (濃淡) かの違いにより、3 つの処理に分類できる。衛星データ処理のように入出力共に濃淡画像である場合は、Morphology 的畳み込み演算 (Morphological Convolution) すなわち、関数 $f(x)$ と関数 $k(x)$ の最大値、最小値を含む演算により処理される。

4.3.5 多重スケールフィルタリング

Morphology におけるフィルタは構成要素のサイズを変えることにより多重スケールに拡張できる。構成要素が関数 (濃淡) の場合、サイズ変換は次のように定義される。

$$nk = \underbrace{k \oplus k \oplus \cdots \oplus k}_n \quad (4-7)$$

ここで、 $n=0$ のとき、上式は原点のみから構成されるただ 1 点の集合となる。これを利用して、 nk から mk (ここに、 $n > m$) への分解も可能となる。空間分解能や対象物の大きさが未知の場合に対しては、サイズ n を順次大きくすることで対処可能となる。

4.4 Morphology による境界検出式

4.4.1 代表的な境界検出式

代表的な濃淡画像における対象画像 (原画像) $f(x)$ の Morphology 的境界は、関数 $f(x)$ に対してサイズ n の構成要素 $nk(x)$ により以下のように与えられる⁴⁻¹²⁾。ここに、 $fs\#(x)$ は出力画像である。

(1) dilation 型

$$fs1(x) = (f \oplus nk)(x) - f(x) \quad (4-8)$$

(2) erosion 型

$$fs2(x) = f(x) - (f \otimes nk)(x) \quad (4-9)$$

dilation 型の境界検出式は、原画像に異なる境界が平行して存在する際、谷（低輝度）側の境界を優先する。同様に、erosion 型の境界検出式は、原画像に異なる境界が平行して存在する際、峰（高輝度）側の境界を優先する。また、初期に dilation を行う処理にはノイズの低減効果があり⁴⁻¹³⁾、逆に初期に erosion を行う処理には孤立点を抽出する効果がある。

4.4.2 多重 Morphology 演算による境界検出式

上述のように、opening 型および closing 型に代表される境界検出式は本来の境界の中心を捉えるものではない。そこで両者の最小をとることにより重複部分を捉えることができる。dilation あるいは erosion の効果を利用した境界検出式は、それぞれ低輝度および高輝度方向の境界を優先的に検出し、かつこれらの境界は構成要素のサイズに比例して、検出される線の太さが拡大する。これら境界の適合度を重ねて表示すれば Fig. 4-1 のように双峰形となり、両者の重複領域すなわち最小値が本来の境界に近いと判断できる。この境界検出式の多重化を定式化すると以下ようになる。

$$fa(x) = \min\{fal(x), fa2(x)\} \quad (4-10)$$

ここに、 $fa1(x)$ は、 $fs1(x)$ のように dilation が erosion を上回る処理により検出された境界情報、 $fa2(x)$ はその逆である。この代表的なものに ATM (Alpha Trimmed Multidimensional Morphological edge detector) や BMM (Blur Minimization Morphological operator) がある⁴⁻¹⁴⁾。ATM は次式で表される。

$$fal(x) = d(x) - c(x) \quad (4-11)$$

$$fa2(x) = o(x) - e(x) \quad (4-12)$$

同様に BMM は次式で表される。

$$fa1(x) = fh(x) - e(x) \quad (4-13)$$

$$fa2(x) = d(x) - fh(x) \quad (4-14)$$

ここに、 $fh(x)$ は、 $fh(x) = \sum f(x+i)/N$ (N はフィルタの画素数) で表されるぼかし画像である。次式は、 $fa1(x)$ および $fa2(x)$ にそれぞれ、dilation 型および erosion 型の境界検出式を用いたものである。

$$fs3(x) = \min\{fs1(x), fs2(x)\} \quad (4-15)$$

しかし、 $fs3(x)$ より検出される境界情報は Fig. 4-1 に示されるように微細なものである。Fig. 4-2 の概念に基づき、 $fs3(x)$ は次式のように書き換えられる。

$$fb(x) = fbo(x) - \max\{fb1(x), fb2(x)\} \quad (4-16)$$

ここに、

$$fbo(x) = d(x) - e(x) \quad (4-17)$$

$$fb1(x) = d(x) - f(x) \quad (4-18)$$

$$fb2(x) = f(x) - e(x) \quad (4-19)$$

であるとき、 $fb(x)$ は $fs3(x)$ と同値となる。Fig. 4-3 で示される概念に基づき $fb(x)$ を拡張すれば、

$$fs4(x) = \max\{d(x) - o(x), c(x) - e(x)\} - \max\{d(x) - f(x), f(x) - e(x)\} \quad (4-20)$$

が得られる。

Fig. 4-3 に示されるように、 $fs4(x)$ は上式の右辺第 1 項で示される広領域境界検出 (Wide-range Edge Detection, WED) と同第 2 項で示される狭領域境界検出 (Narrow-range Edge Detection, NED) を組み合わせた処理と考えられる。したがって、これを多重 (領域) 境界検出 (Wide-Narrow-range Edge Detection, WEND) として定義される。




Fig. 4-1 Multiplex concept of edge detection (1)




Fig. 4-2 Multiplex concept of edge detection (2)




Fig. 4-3 Multiplex concept of WNED

4.5 ケーススタディー

4.5.1 対象地域と使用データ

解析には、愛知県庄内川流域における 100 ライン×100 カラムの LANDSAT/TM データ (Path=109, Row=36, 1987 年 11 月 11 日撮影) と愛知県木曽川流域における 512 ライン×512 カラムの TM データ (Path=109, Row=35, 1994 年 6 月 1 日撮影) を用いた。庄内川画像における河川は幅員が小さく、ほぼ一定である。これに対し木曽川画像における河川幅員は大きく、また、場所によって変化する。この特徴を利用して、庄内川画像は構成要素を固定した手法間比較に、木曽川画像は構成要素のサイズ拡大に伴う出力形態の比較に用いた。

また、本解析では TM のバンド 3 (Band3) とバンド 4 (Band4) を用いて次式で示される植生指標 (NVI) 画像 (8 ビット化) を解析対象原画像とした。

$$NVI = \{(Band4 - Band3) / (Band4 + Band3) + 1.0\} \times 127.5 \quad (4-21)$$

Fig. 4-4 および Fig. 4-5 に各流域における原画像 (NVI 画像) を示す。本解析で扱う Morphology 解析は単一画像に対する処理であるため、NVI により複数バンドの情報を単一画像に圧縮することができる。また、NVI は緑被状態を概略的に把握できるとされており、NVI 画像に対して数段階の量子化を行えば、それだけで水域と陸域の分離がある程度容易となる⁴⁻⁵⁾。

4.5.2 構成要素

Morphology においては、構成要素は方向に依存しない rolling ball フィルタを代表に、quoit フィルタ⁴⁻⁶⁾等、対象とする画像の形状に合わせたものを用意することが可能となる。この構成要素は単純な構成要素に分解することも可能であり、方向に依存した形状の同定作業には特に有効である。対象とする形状が不安定な場合に対しても、構成要素を分解し、これより作成される小さな構成要素をくり返し適用することにより対処が可能となる^{4-7), 4-8)}。

一般的に、濃淡の Morphology に対して矩形の構成要素によりフィルタリングを行えば、その矩形範囲内における最大値 (最小値) が出力される。空間分解能を有効に活用することを前提とした解析においては、矩形範囲を対象とするより構成要素を分解し詳細な検出を行うことが望ましい。Fig. 4-6(a)で示される矩形の構成要素を縦・横・斜め (2 方向) の 4 方向に対して線状の成分を持つ構成要素に分解した Fig. 4-6(b), (c), (d) および (e) を用いることにより、各構成要素の形状に依存するかたちで、矩形

の構成要素よりも詳細な境界情報が得られると推測できる。しかし、衛星データより得られる地理情報に含まれる平面的な大きさは、センサーの分解能や自然地形の大きさに依存する。また、河川を代表とする線状の被覆形態を有する対象物に対しては、用いる線状構成要素によっては境界が検出できない場合もある。したがって、処理の初期段階としては基本的な矩形形状のChessboard フィルタ^{4-9), 4-10), 4-11)}を用いることが適当と考えられる。3×3画素($n=1$)のChessboard フィルタはFig. 4-6(a)に示される。ここに、構成要素のサイズ n に対し、構成要素の画素数は $(2n+1) \times (2n+1)$ で表される。構成要素のサイズ n は、原画像サイズを満足する全ての自然数を考慮することが可能である。

4.5.3 従来法と多重式の適用結果の比較

Fig. 4-7, Fig. 4-8, Fig. 4-9 および Fig. 4-10 は、Fig. 4-4 を原画像として、それぞれ $fs1(x)$, $fs2(x)$, $fs3(x)$ および $fs4(x)$ により出力された境界検出結果画像である。Fig. 4-11 は境界検出結果画像の座標(50,0)-(50,99)における断面を表示したものである。図中左側の $f(x)$ が小さい領域が実際の河川の位置である。同図には、従来手法との比較のために Laplacian による処理結果を併記した。

Fig. 4-11 に示されるように、 $fs1(x)$ と $fs2(x)$ により算出された結果から、両式の画像断面の凹凸に対する境界の捉え方の違いが確認できる。 $fs1(x)$ と $fs2(x)$ を用いて計算される $fs3(x)$ は、 $fs1(x)$ と $fs2(x)$ の中間点近傍を検出し、画像断面から判断した河川境界とほぼ一致していることが確認できる。しかし、画像中の河川左右に見られるような河川以外の境界も多々確認できる。これに対し、WNED ($fs4(x)$) は $fs3(x)$ と同等の境界検出精度を保持した上で、 $fs3(x)$ に見られる誤検出画素を低減できている。さらに、検出された成分も細線化されている。以上の結果から、WNED は構成要素の範囲内で基点から基点までの閉じた区間における原画像値の変化を検出する効果があり、仮に閉じた区間であっても構成要素の範囲を超えるものに関しては境界として検出しないことが判る。

次に、従来手法との比較を行う。Fig. 4-11 の結果より、Laplacian と比較した場合の WNED の有効性は明らかである。Laplacian は境界に対してその両側に正負のピークを出力することが確認できる。実際の境界位置に相当するのは正負のピークをつなぐ曲線と 0 レベルとの交差する点であるとするゼロ交叉法の考え方を考慮しても、Laplacian の WNED に対する優位性は確認できない。




Fig. 4-4 Original image of study area 1
(Shonai river)




Fig. 4-5 Original image of study area 2
(Kiso river)




Fig. 4-6 Structuring elements




Fig. 4-7 Output image of $fs1(x)$ for Shonai river TM data




Fig. 4-8 Output image of $fs2(x)$ for Shonai river TM data



Fig. 4-9 Output image of $fs3(x)$ for Shonai river TM data







Fig. 4-10 Output image of $fs4(x)$ for Shonai river TM data



(a) for $fs1(x)$, $fs2(x)$



(b) for $fs3(x)$, $fs4(x)$



(c) for $fs4(x)$, Laplacian

Fig. 4-11 Image section for each output

4.5.4 サイズの拡大による WNED の効果

Fig. 4-12 は、構成要素のサイズの拡大に伴う $fs1(x)$, $fs2(x)$, $fs3(x)$ および WNED ($fs4(x)$) の境界の捉え方の違いを示したものである。原画像は Fig. 4-5 を用いている。各境界検出式について左から順に構成要素のサイズを拡大 ($n=2,5,12$) している。出力された画像を各段 (各検出式) ごとに比較すると、構成要素のサイズの拡大に伴い、 $fs1(x)$ については河川中央 (谷) 側に、 $fs2(x)$ については陸域 (峰) 側に境界が肥大していく様子が確認できる。 $fs1(x)$ と $fs2(x)$ の重複領域を検出する $fs3(x)$ は真の境界と推測される領域から谷・峰両側に境界線の肥大が見られる。以上から、 $fs1(x)$, $fs2(x)$ および $fs3(x)$ はその適用に当たって構成要素を最小に設定する必要がある、構成要素の形状を利用する Morphology の利点を十分に活用することができない。これに対し、WNED による結果からは境界の肥大は確認されない。前節の結果と同様、このことから WNED は構成要素のサイズに対応した閉区間の境界を検出する効果があると判断できる。

4.6 結語

本章により得られた結論は、以下のように整理できる。

- ① dilation 型および erosion 型の Morphology 境界検出式は、それぞれ低輝度側および高輝度側の境界を優先する。両者の重複領域 (最小値) をとることにより、境界の中心近傍を検出することが可能となるが、これだけでは構成要素に含まれる全ての変化を捉え、誤検出画素が多くなる。
- ② ①の問題は、広領域と狭領域の Morphology 境界検出式から構成される多重境界検出式 (WNED) により対処できる。WNED は基点から基点までの閉じた区間における境界情報を的確に検出し、かつ検出成分と非検出成分の差異も明確となる。
- ③ これまで境界検出に有効と考えられてきた Laplacian やゼロ交叉法は、任意の対象物に対しては統計的に効果があると思われるが、対象とする形状が定まった場合に対しては Morphology に対する優位性は見い出せない。
- ④ dilation 型および erosion 型の境界検出式あるいは両者の重複領域の検出として表される境界検出式は、構成要素のサイズの拡大に伴い検出される境界が肥大する。したがって、Morphology における多重スケールフィルタリングを活用することが困難となる。
- ⑤ WNED は④で挙げた構成要素のサイズの拡大に伴う境界の肥大はなく、構成要素のサイズに従った、より正確には構成要素のサイズ以下の境界を的確に検出

する効果がある。構成要素のサイズの拡大は多重スケールフィルタリングにより容易に実現できる。

- ⑥ 構成要素のサイズに対応した閉区間の境界情報を検出する WNED の特徴を利用すれば、サイズ n の構成要素により出力された結果からサイズ ($n-1$) の構成要素により出力された結果を減算することにより、着目するサイズの境界成分の抽出が可能となる。しかし、このことは、適切な構成要素を用意しなければ、適用する構成要素のサイズ以下の境界情報の検出が困難となることを意味する。対象とする閉区間の情報が未知の場合には、他の手法で閉区間の画素数の概略を知るか、WNED のくり返し演算をする必要があることが問題点として挙げられる。
- ⑦ WNED を多次元画像に対する処理に拡張することにより、より高性能な境界検出 (地形変化検出) が可能である。




Fig. 4-12 Output images for Kiso river TM data

第5章 IRデータを用いた山地斜面崩壊地点の規模・形状の推定方法

CHAPTER 5 DETECTION OF SLOPE FAILURES AND ESTIMATION OF ITS SIZE AND SHAPE USING INFRARED RAY DATA

This chapter describes the applicability of morphological operations for slope failure detection using low resolution remote sensing imageries. The distribution of remote sensing data on the failure area is formulated using a diffusion equation based on the distribution of collapsed soils. The equation is presented by gray-scale morphological operations. The method is applied to the detection of slope failures triggered by the Hyogo-ken Nambu Earthquake. As the result, the reliable sizes, shapes and morphological types of the failures are computed with an accuracy of 75%. By using the parameters which have been used in the above case study, the method is also applied to failures caused by heavy rainfall after the earthquake. The results show the applicability of the method for time series monitoring using satellite imageries.

KEY WORDS : Slope Failure Detection, Morphological Failure Type, Mixed Pixel, Mathematical Morphology

5.1 概説





本章では、被災領域が広域に及び、短期間での地上の調査が困難である山地を対象とし、植生と崩壊土砂の混在画素の平面的な分布特性を分析し、斜面崩壊規模・崩壊形態を IR 画像から正確に検出する手法についての一提案を行う。この方法論として、構成要素と呼ばれるフィルタの形状を利用して構成要素で緑被率の平面的な連続性を表現できる Mathematical Morphology の概念を利用する。手法の検証は、1995 年兵庫県南部地震およびその後の降雨を直接の誘因として六甲山系で発生した斜面崩壊⁵⁻¹⁾を対象とするケーススタディーにより行う。

5.2 斜面崩壊検知における衛星データの有効性と Morphology の効果

本章で提示する手法は、これまでに提案されてきた手法^{5-2), 5-3), 5-4), 5-5), 5-6)}での成果に比べ、崩壊形態および崩壊面積・形状を精度良く知ることができるところに特徴がある。崩壊位置の点的決定だけではなく、崩壊の詳細な情報を知ることが目的とすることから、本章では斜面崩壊検知の語で記する。広域な対象からの概括的な斜面崩壊検知を行う場合、低分解能のデータを解析することが必要となる。このため、比較的小規模に発生する斜面崩壊に対しては、崩壊土と植生などが混在した画素（ミクセル）を対象とせざるを得ない問題が生じる。この問題に対して、崩壊によって土砂が平面的な広がりを呈することにより隣接画素に影響を与える状態をモデル化することで対処できる。すなわち、衛星データが構成するスペクトルの空間分布形態との関係によって崩壊の状態が推定できる。空間分解能の異なるデータに対しても手法の適応性を広げるためには、空間分解能を一つのパラメータとして取り扱うことができる方法論による定式化が望まれる。この方法論として、集合論的操作からなる画像の変換手法に関する一貫した数学的な理論体系である Mathematical Morphology^{5-7), 5-8)}を利用することができる。

一方、衛星データは継続的なモニタリングを行う手段としても有用である。衛星データの周期性から、雲量等の条件が整う範囲内で、再訪時間間隔ごとの時系列処理が可能となる。一旦崩壊の生じた地点は定常状態に至るまでに崩壊領域を拡大し、また崩壊に至らなかった地点でも他の誘因が加わることで崩壊を生じ易くなる。六甲山系では兵庫県南部地震後の2度の集中的な降雨により、約50の斜面崩壊が確認され、確認されていないものはその数倍になると見られている^{5-9), 5-10)}。このことから、衛星データを用いた斜面崩壊検知の必要性が見い出せる。

Table 5-1 Classification of slope failures

形態	特 徴	備 考
落下	多くは空中をとぶ。自由落下あるいは衝撃により跳ねてとぶこともある。通常、崖の部分に発生するため平面形状は崖に沿った線状を成す。線状に斜面崩壊が形成される場合、線状の斜面崩壊の長辺方向に対して直角方向(短辺方向)が落下方向となる。	
転倒	底面から重心が外れて倒れる。その結果、落石等を生じる。河川の屈曲や海岸における波による洗掘に起因する。土塊の体積の差異を除けば平面形状は落下と変わらない。	
滑動	一から数枚のせん断面に沿って土塊が移動する。すべり面が確認できる場合もある。すべり面(円弧)に沿って移動する回転運動と平面に沿って並行に移動する変移運動に区別される。遷急点において比較的大規模に発生することが多い。通常、面的な広がりを成す。	
水平展開流動	明瞭なすべり面が見られない動きであり、基盤岩によく見られる。地盤の液状化や塑性的な流れによる引っ張り移動が含まれる。表層と深部の変形速度の違いや傾斜がある場合等には流動と呼ばれる。	

5.3 斜面崩壊検知の基本的な考え方と Morphology の効用

提示する斜面崩壊検知手法の基本的な考え方は、崩壊による土砂の被覆により、地表を被覆している緑被物の占有率が崩壊の平面的重心を最小として徐々に変化する過程をモデル化し、衛星データの輝度値の平面的な分布がこのモデルに従うときは崩壊である可能性が高いとするものである。この際、平面的な画素の集合状態を取り扱う必要が生じる。Morphology は集合論的な観点から対象画像が構成する空間分布を濃淡関数として扱うことができることから、連続性を含めた検知手法の構築には有効である。また、Morphology では構成要素と呼ばれるマスクについて任意の形状およびサイズとして定義される大きさを自由に設定できる。したがって、Morphology は空間分解能の異なるデータを取り扱う場合や、単位マスクの大きさを変更する場合も比較的容易に対応でき、プログラムの改造等に要する時間の短縮を図ることができる。

5.4 検知対象とする斜面崩壊形態

崩壊の形態が異なる場合、検知フローの中に崩壊形態ごとに崩壊状態を推定するルーチンを設けた方が精度が向上することは容易に推察できる。この観点から、衛星データからの検知精度を考慮した上での崩壊形態のカテゴリ設定を行う。Varnes による崩壊の運動形態からの分類⁵⁻¹³⁾およびこれらの主要な特徴は Table 5-1 に示さ

れる。Table 5-1 の崩壊形態の存在を兵庫県南部地震により生じた斜面崩壊について、航空写真からの判読により調べた結果、同表中の 4 分類の判別は不可能であるものの、落下・転倒（以下、落下で略記する）と滑動・水平展開・流動（以下、滑動で略記する）の 2 分類に対しては特徴的な性質の違いを見い出している。落下による崩壊は線状の平面形状を有し、短辺方向に落下し、滑動による崩壊は面的に生じ、そうでないときでも谷に沿って崩壊が進展することなどである。

5.5 斜面崩壊検知に用いるパラメータ

斜面崩壊検知に用いる情報は、実際に生じた斜面崩壊の状態と衛星データとのキャリブレーションにより得られる。本手法では崩壊土の平面的な広がり方および崩壊面積占有率から推定される平均的な崩壊面積が必要となる。ここでは、この面積を部分崩壊面積と定義する。斜面崩壊検知に必要なパラメータは、衛星データの CCT カウントと崩壊面積の関係式を支配するものである。以下では、手法の拡張性も考慮して、衛星データの CCT カウントを DN (Digital Number) で表すことにする。

5.5.1 崩壊面積と DN との関係

衛星データの値は、画素内面積占有率とピュアピクセルでの DN の畳み込み演算より得られると考えて良いため、部分崩壊面積は土壌域の面積占有率を用いた換算式により容易に与えられる。ここでは、次式のように、緑被域のピュアピクセルでの DN を切片とする線形の簡易的な換算式を考える。

$$f = \begin{cases} f_{green} + C \cdot a & (a < a_s) \\ f_{soil} & (a \geq a_s) \end{cases} \quad (5-1)$$

ここに、 f_{green} は緑被域の DN、 f_{soil} は土壌域の DN、 a は斜面崩壊面積、 C は係数である。TM データを例にとり、兵庫県南部地震によって崩壊が生じた地点における崩壊形態ごとの部分崩壊面積換算式を回帰分析により求めると、Fig. 5-2 に示されるように、滑動の形態に対しては Fig. 5-1 の関係式が成立する。Fig. 5-2 の(a)は崩壊の重心における DN と部分崩壊面積の関係、(b)は崩壊の重心およびその周辺画素の平均 DN と部分崩壊面積の関係を示したものである。ここに、崩壊の重心は、崩壊地に相当する範囲内で DN の最大値を有する画素としている。なお、当該対象地域において、ほぼピュアピクセルと判断できる緑被域および崩壊地の平均 DN は、それぞれ 31 および 93 であった。ここで、崩壊地は旧崩壊地と新崩壊地の両者を含んでいる。また、新崩壊地と旧崩壊地の平均 DN は同じとしている。しかし、落下に対してはこ

の相関は得られない。ただし、落下においては崩壊の重心に極端に DN の大きい画素が確認できる。これは、もともと岩塊等が露頭していた崖であった、あるいは崩壊によって被覆物が完全に剥落された等の原因による。この隣接画素の DN には影響、すなわち DN の変化がほとんど見られない。これは、崩壊による被覆物の飛散、これに伴う土砂の混合が少なかった可能性を示す。以上より、DN の最大値から推定される斜面崩壊面積が近傍画素の DN の平均値から推定されるそれに対して卓越している場合、落下である可能性が高いという関係が導かれる。

5.5.2 崩壊面積と DN の平面的な広がり方との関係

衛星データの平面的な広がり方に着目した本手法においては、一つの斜面崩壊による土砂の移動が始まる部分と移動がおさまる部分との関連性を見い出す必要がある。ここでは土砂の移動過程のモデル化、すなわち崩壊の重心からの距離 (x) と DN ($f(x)$) との関係づけを行う。大規模な崩壊の認められた地点からサンプルデータを取得し、上述の x と $f(x)$ の関係を調べた。崩壊土砂の移動範囲は未知であることから、境界条件 $f=f_{finite} (x=-\infty)$ および $f=f_{finite} (x=\infty)$ を満足するようにサンプルデータを表現する非線形の近似式を考え、次式を得た。

$$f(x) = f_0 \cdot \exp\{-x^2/D\} \quad (5-2)$$

ここに、 f_0 は $x=0$ における $f(x)$ の値、 D は定数である。前節と同様に、TM データを例にとった際の上式の間接関係を Fig. 5-3 示す。

5.5.3 斜面崩壊地点の検知手法の流れ

以下は、上述 2 つのパラメータを用いて崩壊形態および状態（規模・形状）を推定する方法である。また、この処理の流れが Fig. 5-4 に示される。

(1) 前処理（準備）

$n \times n$ 画素のマスク内における DN の最大値 (Fig. 5-1 の関係が増加関数の場合) および DN の平均値と斜面崩壊面積に関する関係式を定める。当該地区のトレーニングデータが得られない場合は、過去のデータに対してヒストグラム補正をした上で、過去のデータに対する関係式を用いる。

(2) 原画像マスクの作成

$n \times n$ 画素のマスクを考え、中心画素における DN が最大となるマスク $G(z)$ を検索する。ここに $z=\{z_x, z_y\}$ はマスク内の座標である。




Fig. 5-1 Assumption of a relation size between failure and the DN




Fig. 5-2 Relation between size of failure and the TM data




Fig. 5-3 Relation between size of failure and distribution of TM data

(3) 部分崩壊面積の推定

(1)で構築した関係式より DN の最大値から推定される部分崩壊面積 A1, マスク内の DN の平均値から推定される部分崩壊面積 A2 を計算する.

(4) 理想的な滑動による崩壊マスクの作成

対象とする崩壊が滑動によるものであると仮定し, 式(5-2)より $G(z)$ の中心から任意の距離 x における DN (f) を推定し, 最大値を中心画素とするマスク $K(z)$ ($n \times n$ 画素) を作成する.

(5) 崩壊形態の分類

次式で示される $S(z)$ を計算する.

$$S(z) = Go(z) - G(z) + A(z) \quad (5-3)$$

ここに, $Go(z)$ は, Morphology における構成要素を $K(z)$ としたときの $G(z)$ の opening 処理, $A(z)$ は中心画素における $S(z)$ の値 ($S(z_0)$) を 0 にするためのオフセットである. $n=3$ としたときの, この処理の一例を Fig. 5-5 に示す. $S(z)$ に対してしきい値マスク ($P1(z)$, $P2(z)$) を定め, 以下の 3 タイプに分類する. この概念を Fig. 5-6 に示す.

I type 1 ($S(z) > P1(z)$)

中心画素の DN が周辺画素のそれに対して卓越しているため $S(z)$ の値が非常に大きくなる。これを、崩壊の重心において DN の大きな物質（岩石等）が露頭したことによるものと考え、落下（TYPE 1）と判定する。

II type 2 ($P1(z) > S(z) > P2(z)$)

式(5-1)より推定される DN の分布状態と実際のそれとがほぼ一致することから、誤差 ($S(z)$) がしきい値の範囲内に入る。したがって、滑動（TYPE 2）と判定する。

III type 3 ($S(z) < P2(z)$)

周辺画素の DN が中心画素のそれに対して卓越しているため $S(z)$ の値が負になる。これを、 $G(z)$ の中心が数画素にわたって存在する、すなわち $n \times n$ 画素を超える大規模な崩壊が生じているためであると考え、TYPE 3 と一旦判定する。以後のステップ ((6)および(7)) で落下（TYPE 1）か滑動（TYPE 2）を判断する。

(6) 崩壊の影響範囲の推定

(3)で得られた部分崩壊面積が衛星データの空間分解能から推定される崩壊面積より大きい場合は、隣接画素に対して、(2)から(5)の作業を繰り返す。

(7) 崩壊方向との整合性の検証

(6)までで得られた崩壊形状と数値標高データより得られる崩壊方向との整合性を調べる。すなわち、崩壊が線状を成し、かつ崩壊方向が崩壊形状の短辺方向である場合、TYPE 1 と判定し直す。

(8) 全体崩壊面積の推定

(7)で得られた部分崩壊面積の重ね合わせにより全体崩壊面積を求める。ただし、落下に対しては A1 は誤差が大きくなるため A2 を部分崩壊面積とする。同様に、滑動に対しては A1 と A2 の算術平均値を部分崩壊面積とする。

(9) 最終結果画像の作成

以上の操作を全画素および全データ（多時期）に対して実行する。災害前後の二時期のデータを用いて、その間に生じた崩壊を検知する場合、それぞれについて検知した斜面崩壊画素を差し引いたものを検知結果とする。

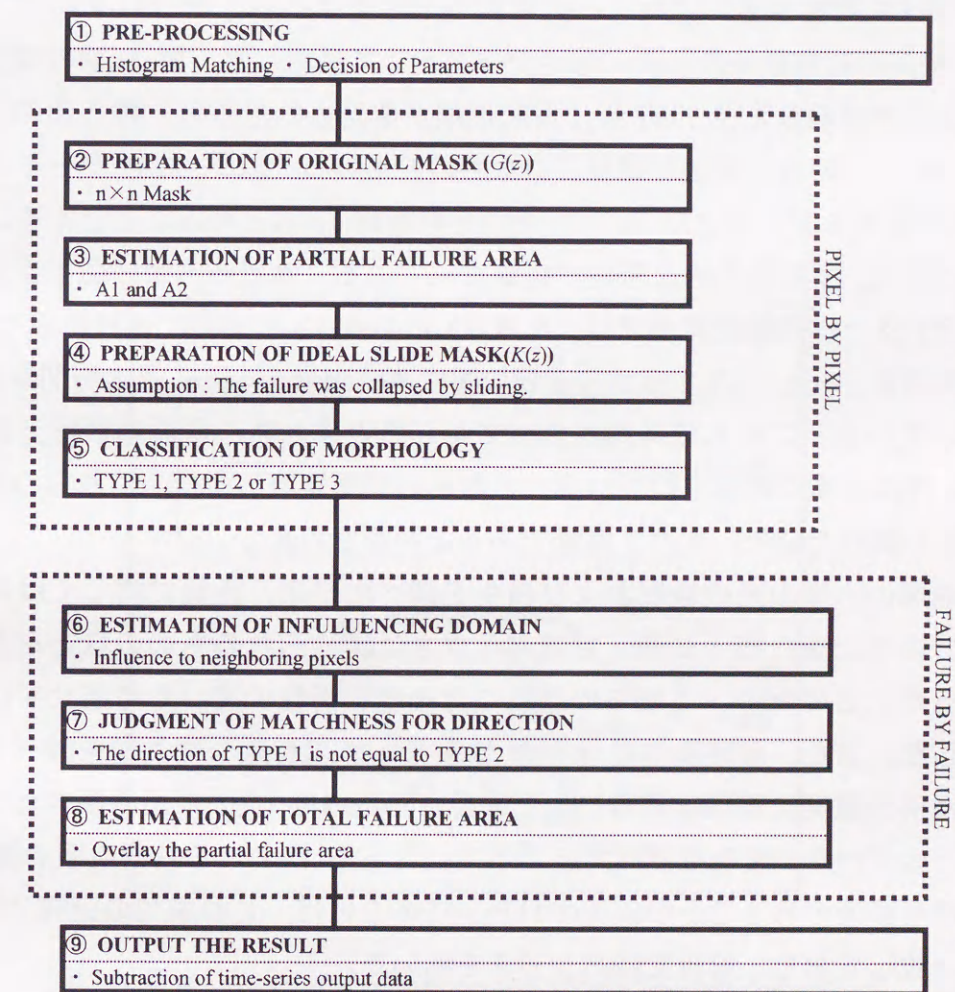


Fig. 5-4 Slope failure detection flow chart

5.6 ケーススタディー

5.6.1 対象地域と使用データ

使用したデータは Table 5-2 のようである。衛星データとしては、最も良く利用され過去のデータの蓄積のある TM データを選定した。解析対象領域は兵庫県南部地震によって生じた斜面崩壊をほぼ全域含む矩形領域、国土地理院発行 1:25,000 地形図で有馬、宝塚、神戸首部、西宮を切り出した。

手法の時刻環境の違いに対する汎用性を確認するため、同一対象地域で誘因の異なる 2 時期の調査結果を精度の検定データとして採用した。第 1 期の調査結果としては兵庫県南部地震直後 1995 年 1 月に崩壊が確認されたもの、第 2 期のものとしては同年 10 月の時点で崩壊が確認されたものを用いる。以下、TM データの撮影時刻である 1995 年 1 月、および 10 月をそれぞれ時刻 t_1 、 t_2 と呼ぶこととする。時刻 t_1 と t_2 の間には、2 度の集中的な降雨が観測されている。建設省六甲砂防工事事務所が設置するテレメータ雨量観測局では、5 月 12 日から 13 日の間に連続雨量 222mm、最大時間降雨量 27mm、7 月 2 日から 6 日の間に連続雨量 261mm、最大時間降雨量 18mm を記録している。これらの降雨によって生じたと思われる斜面崩壊は、各集中降雨後に 20 件以上ずつ確認されている。これらの斜面崩壊の中で、これらの崩壊形態を判読により調べた結果、すべて滑動であると判断された。

対象地域の六甲山系の地質および植生を調べた結果、地盤に関してはほとんどが花崗岩であり、また植生に関してはバラツキは認められるもののほとんどが同一樹種であった。このため、これらの違いによる反射特性の違いを考慮せずに解析することとした。また、崩壊検知に対する TM データの有効な波長帯を調べるために、兵庫県南部地震後に航空写真等により確認された 192 点の斜面崩壊地点についてバンドごとのデータの変化を調べたところ、バンド 5 における斜面崩壊前後の DN の変化が最も顕著であることが確認された。このことは、これまでの研究^{5-2), 5-3)}による結果と一致しており、解析ではバンド 5 を用いた。

5.6.2 精度評価の考え方

時間的・人的な制約から短時間の航空写真判読により得られる情報には限度があり、判読で確認できない地点でも後になって崩壊の存在がわかる場合も少なくない。この事実は、本章の結果で明らかになる。したがって、判読結果が当該時刻における全崩壊情報であるとして精度を検定すれば、判定結果は低く評価される。しかし、判読と現地調査により完全な崩壊地図を作成するには多くの時間を要し、この間に別の誘因で崩壊が生じることもあることから、一時刻での一つの誘因による完全な崩壊地図を作成するのは極めて困難である。したがって、当該時刻の判読結果を仮

の精度検定データとし、これより与えられる精度を「見かけの精度」として評価し、相対的な判断基準とする。見かけの精度 (VA) は次式で示される。

$$VA = DF/AF \times 100 \quad (\%) \quad (5-4)$$

ここに、AF は確認された崩壊数、DF は検知された崩壊数である。ただし、この精度判定に当たっては崩壊形態が明らかな点だけを用いている。




Fig. 5-5 An example of proposed slope failure detection




Fig. 5-6 Judgement of slope failure types

Table 5-2 Data used in the case study

Data	Remarks
Remote Sensing Data	LANDSAT/TM, Path=110, Row=36, Mar. 23, 1993 (t_0)
Remote Sensing Data	LANDSAT/TM, Path=110, Row=36, Jan. 24, 1995 (t_1)
Remote Sensing Data	LANDSAT/TM, Path=110, Row=36, Aug. 4, 1995 (t_2)
Vegetation Data	1:25,000 VEGETATION MAP
Geology Data	1:500,000 GEOLOGY MAP, KYOTO
DTM	FD MAP 25000 (ARIMA, TAKARAZUKA, NISHINOMIYA, KOBE)
Slope Failure Data	AERIAL PHOTOGRAPHS
Verification Data	1:8,000 AERIAL PHOTOGRAPHS

Table 5-3 Accuracy (%)

Size of Failure(m ²)	$\leq 900\text{m}^2$		$\leq 1800\text{m}^2$		$1800\text{m}^2 >$	
Actual TYPE	1	2	1	2	1	2
Detected as TYPE 1	-	0	33	0	100	25
TYPE 2	-	48	0	73	0	75

Total # of extracted pixels : 3916 (about 1000 points)

5.6.3 同一時刻のパラメータを用いる場合の精度

兵庫県南部地震による斜面崩壊地点は、Plate 5-1 に示されるように五助橋断層と諏訪山断層および芦屋断層に沿って分布している。Plate 5-2(b)において赤く示される点は、時刻 t_1 に確認された斜面崩壊情報と 1995 年 1 月の TM データとの関係から得られるパラメータ (Fig. 5-2, Fig. 5-3) を用いて同データに本手法を適用した結果、崩壊地点であると判断された画素をプロットしたものである。同様に、Plate 5-2(a)において赤く示される点は、1993 年 3 月の衛星データより求まるパラメータを用いて崩壊地点を検知した結果である。Plate 5-2(b)の検知地点から Plate 5-2(a)の検知地点の差画像が、これらの時間の間の崩壊、すなわち兵庫県南部地震を誘因とした斜面崩壊であると考えることができる。その崩壊地点の分布状況は、実際に判読によって確認された分布と同様の傾向を示しており、概括的に良好な把握ができているものと判断できる。見かけの精度算定に用いた崩壊地点の総数は、崩壊面積 900m^2 (1 画素相当) 未満が 25 ケ所、同 900m^2 以上 1800m^2 (2 画素相当) が 18 ケ所、 1800m^2 以上が 6 ケ所である。この内、落下の形態は計 5 ケ所、他は滑動の形態である。Table 5-3 に示されるように、1 画素程度以上の崩壊であれば、崩壊地点か否かの判定は可能であり、2 画素程度以上の崩壊であれば、形態まで判別できることがわかる。また、形態まで判別することにより推定面積も精度が向上することが見い出せる。

Table 5-3 で示される精度の相対評価を行うために、特徴空間を利用する方法と比較した。比較に用いた手法は、教師なし分類の ISODATA クラスタリング、および教師付き分類において理想的な環境下で精度の高い分類が実行できるニューラルネットワークの 2 手法である。ただし、画素単位で特徴空間を分類する手法は、一崩壊としての連続性の識別が困難であるため、崩壊面積および崩壊形状を推定することができない。このため、精度比較においては検知結果の正解画素数を総検知画素数で除したものをを用いた。この結果、提示手法の精度を 1.00 としたときに、ISODATA

クラスタリングで 0.54, ニューラルネットワークで 0.77 であった。その処理に要した時間は、同じく提示手法を 1 としたとき、ISODATA クラスタリングで 10~20, ニューラルネットワークで 100 以上であった。以上の結果より、また崩壊の面積や形状まで推定できるという利点から考えて、提示手法の有効性が認められる。

5.6.4 パラメータの汎用性

前節で使用したパラメータを用いて地震後の降雨によって崩壊したとされる時刻 t_2 の崩壊検知を行った結果を検討する。

(1) 時刻 t_1 , t_2 で崩壊有り

時刻 t_1 で崩壊であると判読され、時刻 t_2 で崩壊が拡大していない地点についての解析結果を Fig. 5-7 に示す。Fig. 5-7(A)は時刻 t_1 での航空写真からの判読により抽出された斜面崩壊である。Fig. 5-7(B)および Fig. 5-7(C)は、それぞれ時刻 t_1 および時刻 t_2 に相当する衛星データから当該斜面崩壊を検知した結果であり、Fig. 5-7(A)の順にしたがって配列されている。同図(b)において崩壊面積が拡大していると判断している以外は、同じパラメータでの検知結果の再現性が確認できる。また、同図(c)において、時刻 t_1 で落下として判定されていた崩壊は、時刻 t_2 の結果では滑動と判定されている。時刻 t_1 と時刻 t_2 の間の降雨により、崩壊地点を覆っていた土が流されたものと推測される。

(2) 時刻 t_1 で崩壊なし、時刻 t_2 で崩壊有り

時刻 t_1 で崩壊が確認されず、時刻 t_2 で崩壊が初めて判読された地点についての解析結果を Fig. 5-8 に示す。Fig. 5-8(A)は時刻 t_2 での航空写真からの判読により抽出された斜面崩壊である。Fig. 5-8(B)および Fig. 5-8(C)は、それぞれ時刻 t_1 および時刻 t_2 に相当する衛星データから当該斜面崩壊を検知した結果であり、Fig. 5-8(A)の順にしたがって配列されている。これらの結果より、異なるデータからでも、崩壊地点をほぼ正確に検知できることがわかる。ただし、時刻 t_1 でのパラメータを用いると、同時刻の検知結果に対して時刻 t_2 での判定結果にややバラツキが見られる。これは、時刻 t_1 は冬季、時刻 t_2 は夏季であったことによる季節変化の影響が含まれているためである。本解析では、ヒストグラムマッチングにより画像濃淡の平均値および分散を補正したが、より詳細な補正やノイズ処理により、このバラツキを抑制できるものと推察される。

(3) 時刻 t_1 で確認されず、時刻 t_2 で崩壊有りと確認

時刻 t_2 で崩壊が初めて判読された地点で、さかのぼって時刻 t_1 の判読を行った際


に崩壊が確認できた地点についての解析結果を Fig. 5-9 に示す。Fig. 5-9(A)は時刻 t_2 での航空写真からの判読により抽出された斜面崩壊である。Fig. 5-9(B)および Fig. 5-9(C)は、それぞれ時刻 t_1 および時刻 t_2 に相当する衛星データから当該斜面崩壊を検知した結果であり、Fig. 5-9(A)の順にしたがって配列されている。多少の過大評価が認められるものの、崩壊状態をほぼ正確に検知できることがわかる。これらの崩壊は、地震直後には航空写真から判読できなかったものであった。時系列処理により過去のデータから崩壊情報を検索し、崩壊の発生時刻を推定することができるという衛星データの周期性に関する利点を証明するかたちとなった。このようにして継続的な検知作業を、人間が行う作業と並行に実施することにより、より効果的な応急復旧作業が行えるものと考ええる。また、Fig. 5-9 では、時刻 t_2 と時刻 t_1 の結果の差よりその拡大分を計算した。Fig. 5-9(b)に示されるように、崩壊領域の拡大過程も推定することができる。

5.7 結語

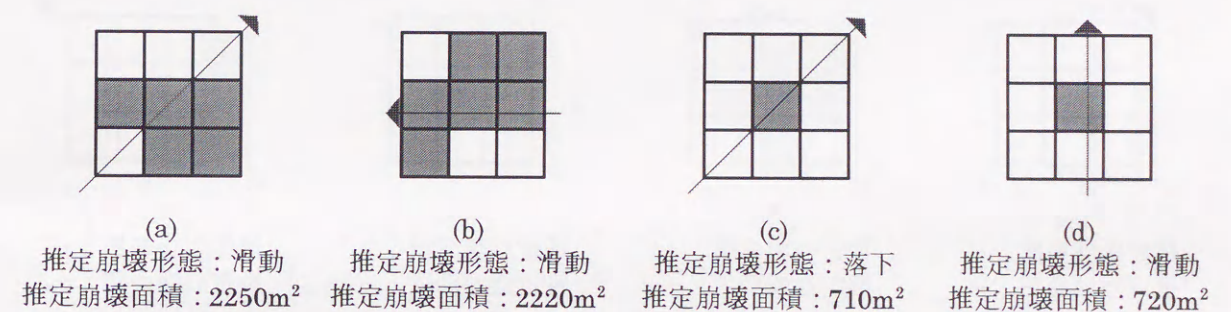
本章によって得られた結論は、以下のように整理できる。

- ① 崩壊土砂の平面的な広がり方を崩壊の運動形態から分類し、モデル化することによって、TM バンド 5 に代表される低分解能 IR 画像データから斜面崩壊の状態、すなわち、崩壊形態および崩壊状態（崩壊面積・崩壊形状）を推定する方法を定式化することができる。この方法論として Morphology が有用である。
- ② 崩壊土砂の広がり方に基づく斜面崩壊検知手法を、パラメータ算定時と同じ TM データに適用すれば、TM データ 1 画素以上の崩壊に対して見かけの精度で約 75% の崩壊検知が可能となる。検知できないものは落下の崩壊形態であるもの、および小規模なものである。落下の崩壊形態の場合、一つの崩壊としての面積は大きく現れるが、その形状が線状を示すことにより、小規模な崩壊が線状に連続したものと同様の結果しか得られず、TM データの空間分解能では限界となる面積以下の評価しか得られなかったものである。TM データ 2 画素以上の崩壊であれば、崩壊形態の判別まで可能となることから崩壊面積算出および形状判定精度が向上する。
- ③ 地震後の集中降雨のように、直接の誘因を異にしても、初期的な誘因の影響をうける地域では、同一パラメータを用いて、TM データから精度を極端に低下させることなく崩壊形態および崩壊面積を推定できる。
- ④ 多時期のデータを用いたケーススタディーの結果から、災害直後の判読では確認できなかった地点での斜面崩壊が確認された。このことより、早急な作業を要する応急復旧計画においては、判読のみから広域な対象領域全域の崩壊情報を検知

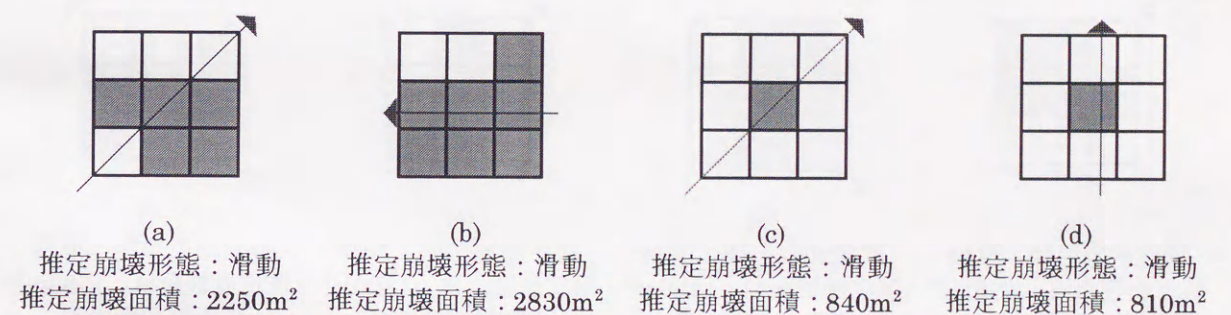
することは困難を伴うことが明らかとなった。以上からも、衛星データを用いた自動的な検知結果を崩壊情報として、あるいは判読の参照情報として与えることは有効である。



(A)兵庫県南部地震直後（1995年1月）に確認された六甲山系の斜面崩壊例
黒：崩壊領域




(B)兵庫県南部地震直後（1995年1月）のデータを用いて検知された六甲山系の斜面崩壊例
各画素のB/W濃淡：崩壊面積占有率（黒いほど崩壊面積が大きい）、矢印：崩壊の向き

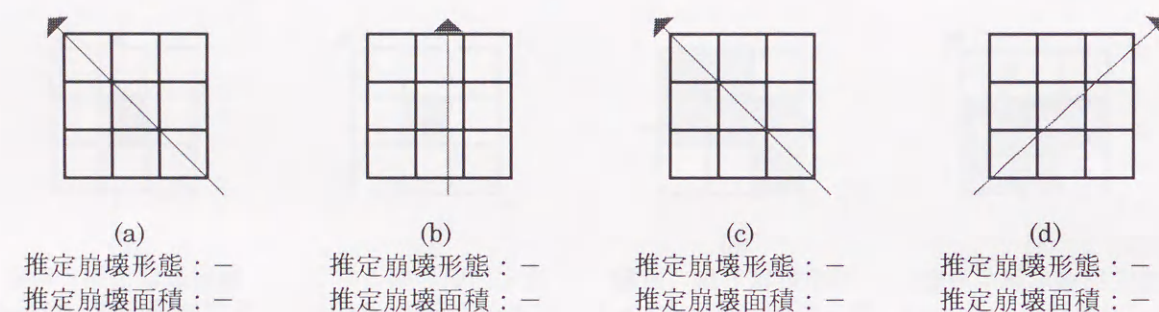


(C)兵庫県南部地震後の集中的な降雨後（1995年8月）のデータを用いて検知された六甲山系の斜面崩壊例
各画素のB/W濃淡：崩壊面積占有率（黒いほど崩壊面積が大きい）、矢印：崩壊の向き

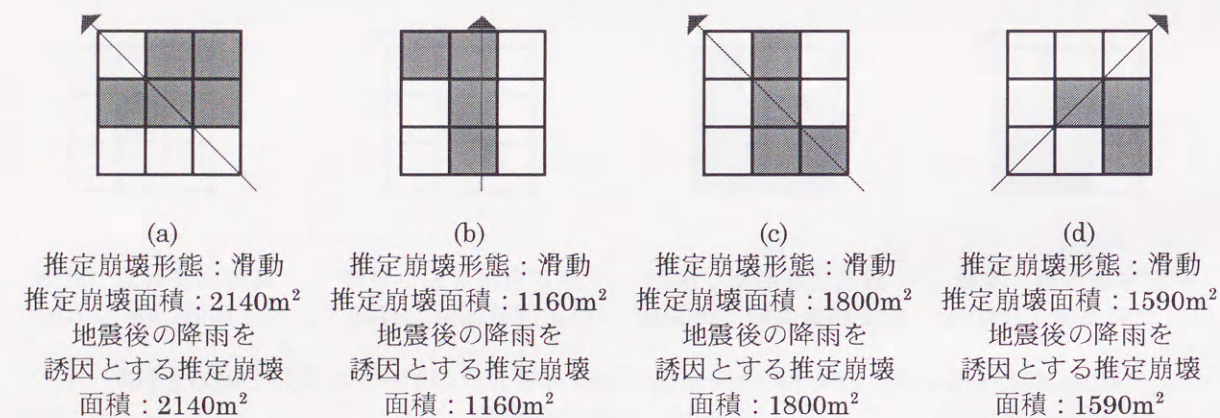
Fig. 5-7 Results (1)



(A)1995 年 10 月に確認された六甲山系の斜面崩壊例
黒: 崩壊領域




(B)兵庫県南部地震直後(1995 年 1 月)のデータを用いて検知された六甲山系の斜面崩壊例
各画素の B/W 濃淡: 崩壊面積占有率 (黒いほど崩壊面積が大きい), 矢印: 崩壊の向き




(C)兵庫県南部地震後の集中的な降雨後(1995 年 8 月)のデータを用いて検知された六甲山系の斜面崩壊例
各画素の B/W 濃淡: 崩壊面積占有率 (黒いほど崩壊面積が大きい), 矢印: 崩壊の向き
地震後の降雨誘因とする推定斜面崩壊面積:
(1995 年 8 月のデータからの検知結果) - (1995 年 3 月のデータからの検知結果)

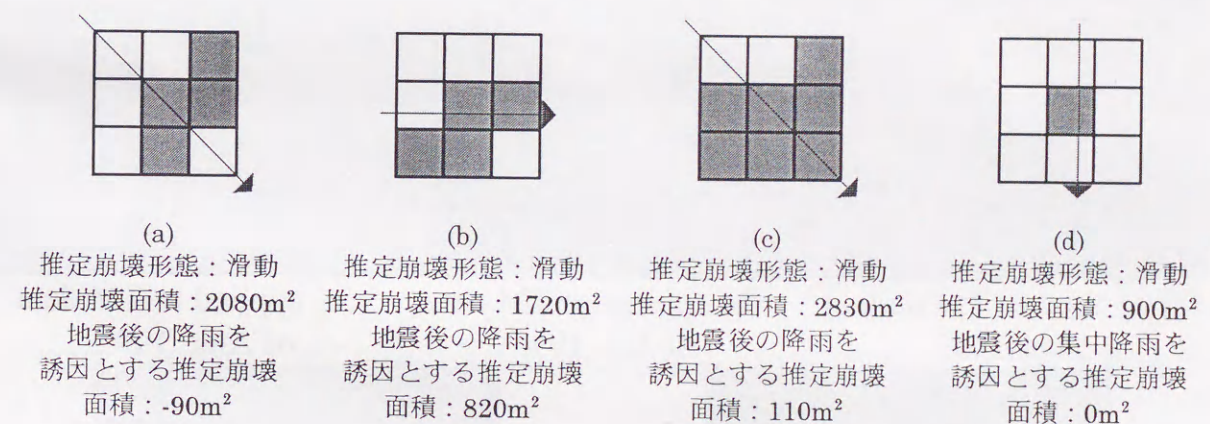
Fig. 5-8 Results (2)



(A)1995 年 10 月に確認された六甲山系の斜面崩壊例
黒: 崩壊領域



(B)兵庫県南部地震直後(1995 年 1 月)のデータを用いて検知された六甲山系の斜面崩壊例
各画素の B/W 濃淡: 崩壊面積占有率 (黒いほど崩壊面積が大きい), 矢印: 崩壊の向き



(C)兵庫県南部地震後の集中的な降雨後(1995 年 8 月)のデータを用いて検知された六甲山系の斜面崩壊例
各画素の B/W 濃淡: 崩壊面積占有率 (黒いほど崩壊面積が大きい), 矢印: 崩壊の向き
地震後の降雨誘因とする推定斜面崩壊面積:
(1995 年 8 月のデータからの検知結果) - (1995 年 3 月のデータからの検知結果)

Fig. 5-9 Results (3)




Plate 5-1 Study area

B/W grayscale: DTM


Blue: Slope failures found after Hyogo-ken Nambu Earthquake

Red: Active faults (Suwayama fault, Gosukebashi fault, Ashiya fault)

○: Verification data (found in Jan. 1995, not expanded by Oct. 1995)

△: Verification data (not collapsed by Jan. 1995, found in Oct. 1995)


◇: Verification data (not found in Jan. 1995, found in Oct. 1995)




(a) applied to TM data of Mar. 1993

(b) applied to TM data of Jan. 1995

(c) applied to TM data of Aug. 1995



(d) Slope failures by earthquake ((b)-(a))



(e) Slope failures by rainfall ((c)-(b))

Plate 5-2 Results

B/W grayscale: DTM, Red: Slope failures detected by 1 image analysis

Yellow: Slope failures detected by temporal image analysis

第6章 リモートセンシングデータを用いた災害監視GIS

CHAPTER 6 HAZARD MONITORING GIS USING REMOTELY SENSED DATA

This chapter describes a GIS model to detect slope failures and predict succeeding slope failures which may occur in mountain side using LANDSAT/TM data and several geographic information. Particularly, this system is applied to the hazard triggered by Hyogo-ken Nambu earthquake and heavy rainfall after the earthquake. To assess the post-hazard occurrence probabilities, two approaches are introduced. One is a method of slope failure detection using remote sensing data, and the other one is a modeling of value function for prediction of slope failures. The results were applied to Rokko Mt. area and showed the effectiveness of the proposed model which gives the weight of value function by neural network.

KEY WORDS : Geographic Information System, Value Function, Slope Failure, Hazard Monitoring, Post-Hazard

6.1 概説

本章では、前章までに提案された手法を統合し、二次災害危険度評価などを可能とする、広域な被災地を対象とする斜面崩壊監視のための地理情報システム（GIS）の一提案を行う。この災害監視GISの検証は、1995年兵庫県南部地震およびその後の降雨を直接の誘因として六甲山系で発生した斜面崩壊を対象とするケーススタディーにより行う。

6.2 斜面崩壊のメカニズムと衛星データを用いた崩壊予測の概念と事例

6.2.1 斜面崩壊危険度の概略的な予測方法

斜面崩壊の危険度を概略的に与える方法として、マグニチュードだけを崩壊が生じる要素（誘因）とする方法が挙げられる。マグニチュードは崩壊の規模とある程度の相関があると考えられるので、いくつかの式が既に提案されている。田村⁶⁻¹⁾は断層または震央から表層滑落型崩壊多発域・散発域の外縁最遠点までの距離の対数と地震規模との間に線形関係を見い出している。安田ら⁶⁻²⁾は地震の規模（マグニチュード）と斜面崩壊が発生した限界の震央距離との関係を示し、マグニチュードと斜面崩壊地点の震央からの距離の対数との間に線形比例関係があることを示した。Keeferら⁶⁻³⁾は1811年以降の世界各地における地震を調査し、斜面崩壊を以下の3形態に分類している。

- ① カテゴリーⅠ：falls, disrupted slides, avalanches
- ② カテゴリーⅡ：slumps, block slides, slow earth flow
- ③ カテゴリーⅢ：lateral spreads, flows

これらとマグニチュードとの関係の対数プロットより、カテゴリーⅠの崩壊が震源から最も離れた地点まで発生していることが明らかとなった。Nakamuraら⁶⁻⁴⁾は斜面崩壊地区の最大震央距離と地震規模の関係を検討している。同様に、Mora⁶⁻⁵⁾は最大震央距離と地震規模の関係をまとめている。しかし、以上の方法は被害全体の平均的な指標を提供するものであるため、個々の斜面災害の程度を推計するには不十分である。

6.2.2 斜面崩壊危険度の詳細な予測手法

土質調査などをもとに、斜面を構成する土砂や岩の強度定数を求め、それを斜面安定解析に適用して、崩壊発生地域を詳細に予測する手法がこれに当たる。現在、以下の2手法が一般的に用いられている。

- ① Wilson et al の方法⁶⁻⁶⁾

② Siyahi and Ansal の方法⁶⁻⁷⁾

Wilsonらは、表層を薄い土塊がすべるモデルを提案している。質量 M の土塊（厚さ H ）が θ なる傾斜をもつ斜面をすべる場合を考える。土の単位体積重量を γ 、粘着力を C 、内部摩擦角を ϕ とすると、すべりが発生するための限界加速度 a は、力の釣合式より次式で示される。

$$a = g[(C/\gamma H) + (\cos \theta \cdot \tan \phi - \sin \theta)] \quad (5-1)$$

したがって、予測しようとする地域内で土の強度定数（ C 、 ϕ ）および斜面の傾斜角（ θ ）がわかっているならば、崩壊が生じる危険度を予測し、被害が生じた地点と類似した状態をもつ地域に対して警告を与えることができる。

Siyahiらは、Koppala⁶⁻⁸⁾によって提案された方法を修正することにより、斜面崩壊のゾーニング方法をさらに進展させた。この方法は、地震によって生じる水平力を水平震度として考慮する安定解析方法である。この方法では、土のせん断強度の深さ方向の分布は深さの一次関数、すべり面は円弧と仮定している。

ただし、これらの方法は土の強度定数（ C 、 ϕ ）と斜面の傾斜角（ θ ）が既知であることが前提であり、これらの調査が不十分な地点に対して危険度を与えることができない。また、誘因に対する影響を取り込むことができないことも指摘できる。これらの問題点は、とくに広域な領域を対象とする場合に問題となる。広域に傾斜角を与える方法は、DTMの解像度に依存する。国土地理院発行のDTMは50mメッシュで整備されているが、原データは250mメッシュ程度であることから、このDTMは精密な予測には適さない。すなわち、精密な予測に適さないデータを用いる必然性から、WilsonやSiyahiらの方法を広域な対象を目的として適用するのは不適であると判断できる。

6.2.3 各自治体における斜面崩壊危険度の予測方法

地方自治体においては、以下のような斜面崩壊危険度予測が試行されている。

(1) 東京都における斜面崩壊予測手法

東京都では主として木造戸建住宅を対象に、高さが5m以上かつ傾斜が30度以上の斜面について、東京都建設局河川部が作成した「急傾斜地崩壊危険箇所調査報告書」に基づき崩壊斜面を推定し、崩壊面積内の人家数から被害を想定し、それ以外の斜面については前回の被災想定結果や国勢調査資料をもとにして想定する方法をとっている。

(2) 千葉県における斜面崩壊予測手法

千葉県所有のデータが不足しているために、他地域で発生した斜面崩壊事例から千葉県の斜面崩壊（斜面災害）危険度を予測する方法がとられている。ここでは外的要因（素因・誘因）として以下を挙げている。

- ①谷密度、②起伏量、③岩盤の硬さ、④断層の長さ、
⑤人工斜面（盛土・切土）の長さ、⑥地表面最大加速度

上述の素因・誘因に対して、数量化理論Ⅱ類により要因分析を行い、斜面崩壊数を算定している。この崩壊数は危険度ランクで表示されている。

(3) 埼玉県における斜面崩壊予測手法

埼玉県では、計 735 箇所の斜面崩壊（危険）地点を対象として予測を行っている。各斜面の常時の安定性（危険性）については、地形や地質、活動状況等を考慮した所定の方法によって個別に判定されている。地震時の危険性については、既存の判定結果の震度の組み合わせによって被害危険度判定表を作成し、総合的な被害危険度を算定している。

(4) 長野県における斜面崩壊予測手法

長野県では、

- ①斜面崩壊危険度、②土石流危険度、③地すべり危険度のそれぞれについて想定地震ごとの分析を行っている。

(5) 静岡県における斜面崩壊予測手法

静岡県の第1次被害想定では各市町村の急傾斜地等崩壊危険箇所における危険戸数が、崖地等の被害の発生しやすい指数であるとして 1978 年伊豆大島近海地震の被害を参考に想定される震源からの距離によって各町村の被害率を3ランクに分けて算定している。

(6) 神奈川県における斜面崩壊予測手法

神奈川県では、過去に発生した斜面崩壊事例より、斜面崩壊に関係すると考えられる幾つかの要因を抽出し、相互の関係を統計的に数量化理論で分類し、斜面崩壊を予測するものである。

以上の既往の研究について利点と欠点を示すと Table 6-1 のようである。

Table 6-1 Summary of previous works

分類	手法	必要なデータ	予測方法	出力	長所	短所
I 概略的	斜面崩壊限界を求める経験式	・震央からの距離				
II 広域	東京都の方法	・急傾斜地崩壊危険箇所 ・急傾斜崩壊危険箇所に含まれる家屋数	・斜面崩壊面積率を用いて斜面の崩壊面積を計算し、これより被災戸数を推定する。 ・傾斜を崖、擁壁、複合の3種類に分類して、それぞれについて被災戸数を算定する。	・被災戸数	・作業量は莫大でなく、全国への適用が可能である。 ・被害戸数が予測できる。	・急傾斜崩壊危険箇所以外での予測は不可能。
	神奈川県、千葉県の方法	・谷密度 ・起伏量 ・岩石の硬さ ・断層の長さ ・人工斜面の長さ ・地表面最大加速度 ・斜面の水平長	・6から7の要因（アイテム）のカテゴリーウェイトの合計から判別得点を計算し、崩壊ランクを決定する。各崩壊ランクには平均崩壊数が与えられる。	・斜面崩壊ランクと平均斜面崩壊数	・かなり詳しく予測できる。	・大変手間がかかり、全国規模での適用が困難。
	埼玉県の方法	・急傾斜地崩壊危険箇所 ・地すべり地 ・常時の崩壊危険度ランク ・調査地域の震度	・常時の危険度ランクを基に、想定する震度に応じて危険度ランク（AからCの3ランク）を与える。 ・常時の危険度は、地形、地質、環境要因などの詳しい調査から決定されている。	・被害危険度ランク（A：高い、B：やや高い、C：低い）	・作業量は莫大でなく、全国への適用が可能である。 ・被害戸数が予測できる。	・急傾斜崩壊危険箇所以外での予測は不可能。
	静岡県の方法（1989）	・急傾斜崩壊危険箇所	・過去の急傾斜地崩壊危険箇所の震害率より危険度を推定する。	・被害危険度ランク（A、B、C）	・作業量は莫大でなく、全国への適用が可能である。 ・被害戸数が予測できる。	・急傾斜崩壊危険箇所以外での予測は不可能。
	静岡県の方法（1993）	・急傾斜崩壊危険箇所 ・地すべり地 ・大規模斜面崩壊危険箇所	・各斜面を地形、地質等の要素点と地震力の両方から危険度を決定する。	・被害危険度ランク（A、B、C）	・手間がかかる	・急傾斜崩壊危険箇所以外での予測は不可能。
	長野県の方法	・傾斜 ・地質条件 ・震源からの距離	・傾斜と地質条件および想定地震の震源からの距離より得られる評点（加点法または上位規定法）で危険度を評価する。 ・土砂災害危険度を、崩壊、地すべり、土石流の3つで評価する。	・崩壊、地すべり（危険度を1から8の点数で表す） ・3つの災害を総合して土砂災害危険度を決定する。	・個々の斜面について、かなり詳しく予測できる。	・大変手間がかかり、全国規模での適用が困難。
	Moraらの方法				・5個の要因を考慮できて比較的詳しく予測できる。	・日本への適用性はまだ明らかにされていない。 ・被害戸数のカウント方法がない。
III 詳細	道路協会の斜面点検票				・個々の斜面について、かなり詳しく予測できる。	・大変手間がかかり、全国規模での適用が困難。
	Wilson, Siyahiらの方法	・土の単位体積重量 ・土の粘着力（ ϕ ） ・土の内部摩擦角（ c ） ・傾斜角 ・土層の厚さ	・力の釣り合い方程式から、すべりが発生するための限界加速度が定式化されている。	・限界加速度 ・崩壊の安全率	・詳細な予測が可能となる。	・ c 、 ϕ の予測が全国的には困難である。 ・手間がかかる。

6.3 災害監視 GIS の要件

6.3.1 災害監視 GIS の定義とその必要性

斜面崩壊が発生した地点を早期にかつ的確に把握すれば、その分布図から緊急避難計画等の行政活動支援に関する有効な情報・資料を提供できる。また、その他の素因との関連性を調べることにより、被災箇所の特徴が判断でき、二次災害の防止に寄与できる。この考え方に基づき、本章では第5章までの方法を統合し、広域な対象における初期災害状態の把握を早期に実現し、得られた情報から二次災害の危険箇所を推定し、以後の対策を支援する方法を提示する。これら災害時の対応に寄与するための一手段として、GIS（地理情報システム）の手法を用いた事例が多く見られる。災害時の対応策の検討に寄与するGISは、防災GISとしてとくに阪神大震災後急激に広まった⁶⁻⁹⁾。ただし、これらのGISは個々の宅地の状態を詳細に記述すること、およびデータの入手が困難なことに起因して限定された対象を取り扱うため、広域な対象を取り扱う場合には困難を伴う。防災GISのニーズが強まる一方、人的被害の比較的小さい山腹における斜面災害を取り扱うGISは他に比して優先順位が低いことも指摘できる。しかし、初期的な被害として人的被害を含まない斜面災害でも、同様の条件をもつ地点で二次災害が発生し、人間活動に影響が及ぶことも否めない。

本論では広域な山腹における斜面災害を一括して把握・推定するGISを斜面（二次）災害監視GISとして定義し、その意義、適用範囲、有効な時間帯等に着目した処理の概念を整理し、六甲山系を対象としたケーススタディーにより検証する。

6.3.2 二次災害推定の考え方と在来法との比較

斜面災害監視GISの最大効果は、被災状態を把握し、生じた事象が同じ様な性格をもつ地点で生じることを予測し、二次災害の防止に利用することである。これまで提案されてきた斜面崩壊予測モデルは、解析時刻以前の要因分析により、解析時刻以降の比較的長いスパンでの崩壊発生を予測するものであるため、地形傾斜や地質の寄与率が高いという一般的な知見で整理され、これに基づいた評価関数（Value Function）が設定されている。しかし、危険度判定に用いる素因ごとに与えられる係数、すなわち個々の因子の重みは、任意の地域における任意の事象に対して一定ではなく、同じ対象地域でも事象発生までの気象状態や誘因の影響度により極端に異なることも予測できる。本研究では事象発生後に初期的に検出された斜面崩壊地点との関係から地域特性を抽出し、これより導かれる個々の要因との関係から二次災害危険度を推定する。この考え方に基づけば、あらかじめ素因ごとの危険度を設定する必要がなく極めて簡易的に対象地域の対象事象に対する最適解が得られる。

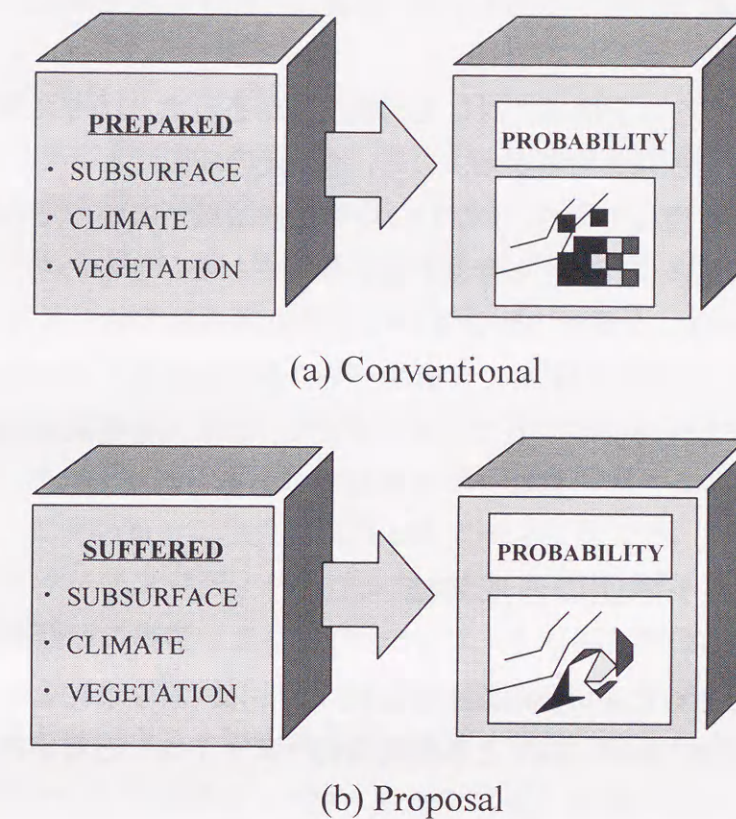


Fig. 6-1 Judgement of hazard occurrence probability

一方、Fig. 6-1(a)に示されるようなこれまでに提示されてきた衛星データを用いた斜面災害危険度の推定方法^{6-10), 6-11), 6-12)}は、衛星データを地形や地質等と同等に取り扱い、各因子の寄与率を得てから崩壊確率の算定を試みている。本来、地形や地質、活断層や震源からの距離減衰関係は定常的な情報である。これに対して衛星データが取得する情報は、撮影時刻の被覆の状態を捉えた“活きた”非定常情報であり、撮影時刻における対象地域の相対的な関係を与える。この考え方から、本論で提示する方法は、Fig. 6-1(b)に示されるように定常データとしての素因情報と非定常データとしての衛星データを別々に考え、それぞれの処理方法に基づく2つの二次災害危険度情報を重ね合わせることで、最終的な二次災害危険度を算定する。

6.3.3 斜面崩壊検知結果の二次災害監視への有効性

第5章で示される崩壊検出結果において兵庫県南部地震直後には判読により確認されなかったが、地震による斜面崩壊として検出されていた地点も確認できる。この原因として、

- ① 地震直後の判読における誤差

- ② 刻直後では崩壊までに至らなかったが、崩壊の可能性を示す情報がTMデータに含まれていた

等が考えられる。これらの全崩壊に対して判読誤差があったとは考え難いこと、兵庫県南部地震直後に検知された崩壊面積よりも、地震後の降雨によって検知された崩壊面積が1割程度大きく現れている、すなわち均等に崩壊域が広がっていることから、後者の原因によるものが多少なりとも含まれると推測される。すなわち、TMデータからの初期災害の検出が二次災害予測あるいは初期災害の被害拡大の推定に充分寄与できるものとする。これと合わせて、衛星データから取得される情報が当該時刻における直接的な物理特性を反映することを踏まえて、二次災害危険度推定の参照情報を与える非定常データとして、衛星データが有効であると判断できる。

6.4 二次災害発生予測図の作成方法

最終的な出力図である二次災害危険度推定値 (P_s) は、第5章による方法で崩壊と判定された斜面崩壊検出結果 (P_d) と各地理情報 (アイテム) と初期的な崩壊地点との関係から得られる素因因果律 (P_p) とによって、

$$P_s = P_d \times P_p \quad (6-1)$$

として与えられるとする。ここに、

$$P_d = \begin{cases} 1.0 & \text{崩壊検出地点} \\ 0.0 & \text{崩壊未検出地点} \end{cases} \quad (6-2)$$

であるので、 P_s には P_p の確率が直接反映される。すなわち、 P_d によって全域を対象に計算される P_p の領域を“活きた情報”によって制限することができる。 $P_d=1.0$ の地点が少なく評価されるときには、 P_d 算定における閾値である最小崩壊面積を小さく設定することで対処できる。また、アイテム (i) ごとのカテゴリー (j) に関する素因因果律 ($P_{p_{ij}}$) が次式により得られる。

$$P_{p_{ij}} = \frac{(i \text{ の } j \text{ に含まれる崩壊面積})}{(\text{全崩壊面積})} \quad (6-3)$$

最終的に、 $P_{p_{ij}}$ に関する評価関数にしたがって素因因果律 P_p を計算する。

6.5 ケーススタディー

6.5.1 ケーススタディーの概要

二次災害危険度の算定を、1995年1月17日の兵庫県南部地震を直接の誘因として発生した斜面崩壊を既知情報として同年5月12、13日に生じた集中降雨を誘因とした斜面崩壊に対して適用した。解析対象領域は、第5章と同じ国土地理院発行1:25,000地形図で有馬、宝塚、神戸首部、西宮に相当する矩形領域である。この領域の北西端座標は (E135° 07' 30", N34° 50' 00")、南東端座標は (E135° 22' 30", N34° 40' 00") である。解析に使用したデータの種別およびその概要を Table 6-2 に示す。また、便宜上、解析時刻 (TMデータの撮影時刻) と崩壊発生時刻の関係を Fig. 6-2 のように定める。二次災害監視GISの概念に基づき、前章に引き続き六甲山系を対象としてケーススタディーを行った結果を以下に示す。本ケーススタディーの目的は二次災害箇所の推定であるため、時刻 t_1 で入手可能な情報から時刻 t_1 から t_2 の間に発生する斜面崩壊に関する二次災害を推定することで、手法の有効性を検討する。ここで、本解析で検討する六甲山系の二次災害の誘因は初期災害の直接の誘因とは異なっている。ただし、当該箇所は地震によって斜面に損傷を受けていることが容易に推測される。また、一般的にも“二次災害”は初期災害の誘因に起因して発生することから、本解析では直接の誘因の違いは解析に組み入れない。

6.5.2 素因と崩壊地点との関係

対象領域全域と斜面崩壊地点における地形傾斜度を比較した Fig. 6-3 より、崩壊はやや急傾斜地で多く発生していることが認められる。ただし、同図は低傾斜面においても崩壊が生じる可能性も示している。Fig. 6-4 は地震によって生じた比較的規模の大きい崩壊と小さな崩壊および降雨によって生じた崩壊 (二次災害) と地形傾斜度との関係を示したものである。二次災害が生じた地点は、その崩壊規模を問わず初期災害における地形傾斜度とほぼ完全な一致を見せる。このことは地震を誘因とした初期災害と地形傾斜度との関係から二次災害危険度を推定すべきであり、力学的メカニズムに基づく方法よりも有効であることを示す。同様の結論は、傾斜方向との関係 (Fig. 6-5, Fig. 6-6) および活断層との関係 (Fig. 6-8) に対しても確認できる。地質との関係に対しても同様のことが Fig. 6-7 より読み取れるが、ほとんどが花崗岩であるため容易に結論づけられない。ただし、震度分布と崩壊地点との関係 (Fig. 6-9) には明確な因果律が認められない。山地における震度階情報が不足しているとはいえ、直接的な地震動を示す震度階を因果律に組み込むことが時には危険であると判断できる。なお、植生に関してはほぼ同一樹種と考えられたことより紙面から割愛した。

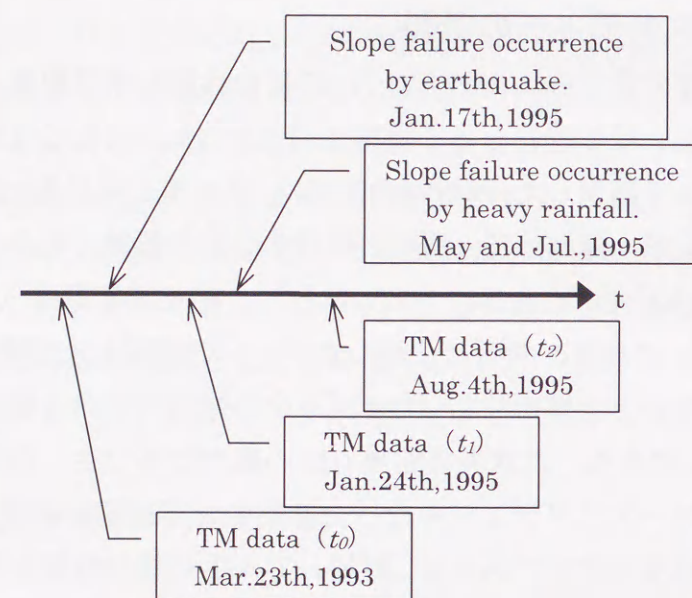


Fig. 6-2 Relation between the time of TM data taken and the time of slope failure occurred

Table 6-2 Items and categories used in this analysis

Item	Source	Format	Category
SLOPE GRADIENT	50m DTM	RASTER	Calculated using 3 by 3 pixels of DTM
SLOPE DIRECTION	50m DTM	RASTER	Clockwise degree from North direction
GEOLOGICAL TYPE	Geology Map, Kyoto (1:500,000)	VECTOR (POLYGON)	Mud · Sand · Gravel · Mudstone · Sandstone · Conglomerategranival rocks · Rhyolite · Others
ACTIVE FAULTS	Japan Active Faults (1:333,333)	VECTOR (LINE)	Reliability grade : 500 m Buffering
SEISMIC INTENCITY	The Great Hanshin Earthquake (1:500,000)	VECTOR (POLYGON)	Seismic Intensity level 7 of JMA standard 500 m or 1000 m Buffering
VEGETATION	Vegetation Map (1:50,000)	RASTER	Pine · Others




Fig. 6-3 Relation between slope failures and slope gradient (1)
(0 : horizontal, 90 : vertical)




Fig. 6-4 Relation between slope failures and slope gradient (2)
(0 : horizontal, 90 : vertical)




Fig. 6-5 Relation between slope failures and slope direction (1)
(azimuth : clockwise)




Fig. 6-6 Relation between slope failures and slope direction (2)
(azimuth : clockwise)




Fig. 6-7 Relation between slope failures and geological type




Fig. 6-8 Relation between slope failures and active faults

F61 : 六甲断層, F62 : 湯槽谷断層, F63 : 大月断層, F64 : 五助橋断層, F65 : 芦屋断層, F66 : 甲陽断層,
F76 : 北摩耶断層, F77 : 満福寺断層, F78 : 布引断層, F79 : 諏訪山断層




Fig. 6-9 Relation between slope failures and seismic intensity 7

Table 6-3 Value function model

MODEL NAME	EXPLANATION
MODEL-A	give the weights based on the slope gradient
MODEL-B	give the weights based on the number of categories
MODEL-C	give the weights by neural network

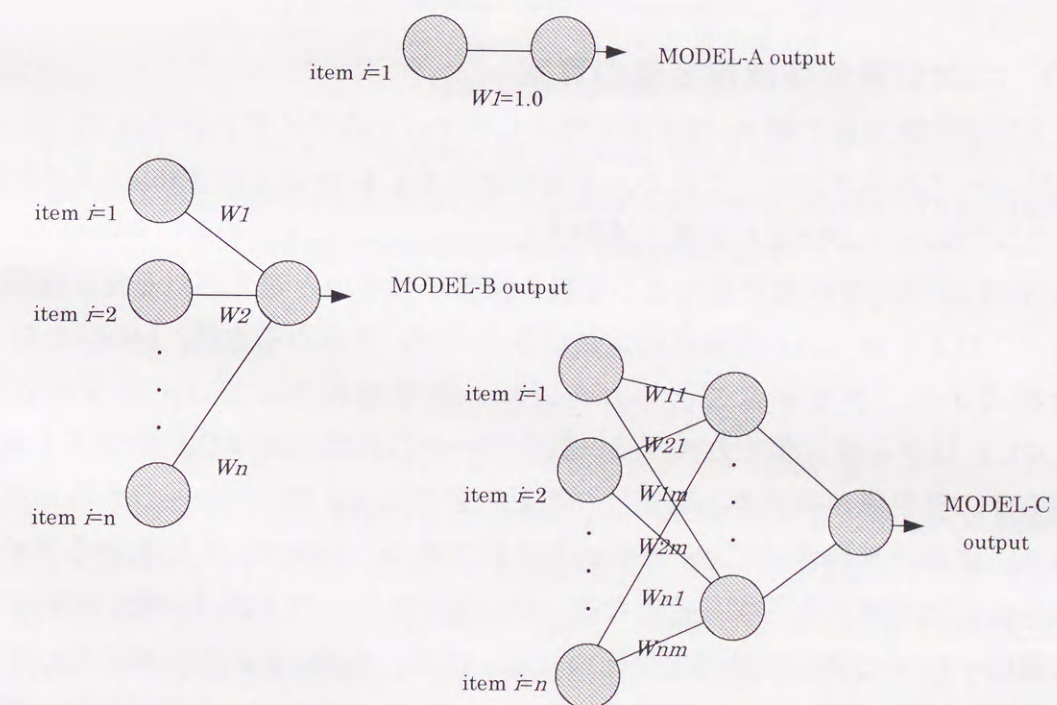


Fig. 6-10 Value function models

Table 6-4 Neural network parameters used in this analysis

Parameter	Value
Number of Input Units	Number of Items × Number of Categories
Number of Hidden Units	20
Number of Output Units	1
Maximum Number of Iterations	10000

Table 6-5 P_p of each model

MODEL NAME		MODEL-A	MODEL-B	MODEL-C
Full scene (P_p)	Mean	0.331	0.331	0.331
	S.D.	0.271	0.271	0.271
	Median	0.271	0.271	0.271
Slope failures Caused by H.N.E.	Mean	0.656	0.709	0.726
	S.D.	0.201	0.191	0.190
	Median	0.702	0.729	0.757
Slope failures caused by Rain after H.N.E.	Mean	0.516	0.569	0.595
	S.D.	0.312	0.341	0.357
	Median	0.647	0.675	0.675

H.N.E : Hyogo-ken Nambu Earthquake
S.D. : Standard Deviation

6.5.3 二次災害危険度推定値の算定

二次災害危険度推定値 P_p は前節で推定した $P_{p_{ij}}$ と各アイテムの重み W_i の畳み込み演算によって計算される。ここで、評価関数を Fig. 6-10 および Table 6-3 に示されるような3つのモデルにより比較・検討する。

MODEL-A は力学的な作用力として最も影響が大きいと考えられる地形傾斜のみを考え、これより得られる危険度推定値のみから P_p を求める方法、MODEL-B は統計的な観点から、アイテムごとのカテゴリー数を重みとして P_p を求める方法、MODEL-C はアイテム間でカテゴリー数やデータの性質が異なり、かつアイテム間には何らかの因果律が存在する可能性があることを踏まえて、ニューラルネットワークで重みと閾値を学習させて P_p を求める方法である。MODEL-B におけるアイテム間の重みの比は事象によらず一定となる。MODEL-C は、カテゴリー数に依存することなく教師データに関する最適化が行われる。なお、Table 6-4 には MODEL-C で用いたニューラルネットワークの諸パラメータを示した。ここで、教師信号は、既崩壊地点を 1.0、未崩壊地点を 0.0 として各 1000 パターンずつ無作為に抽出した。




Fig. 6-11 P_s versus frequency of slope failures caused by rainfall
(Vertical axis is given by (number of predicted pixels) / (number of actually collapsed pixels))





Fig. 6-12 P_s versus frequency of slope failures caused by rainfall
(Vertical axis is given by (number of actually collapsed pixels) / (total number of predicted pixels in study area))

Table 6-5 は、上述の3つのモデルによって得られた P_p の統計量を示したものである。ただし、各モデルで得られる P_p には絶対値にずれがあることから、比較検討を容易に行うためにヒストグラムマッチング処理を行った。これによって、全域での平均値・標準偏差がほぼ等しくなっている。しかし、地震で生じた崩壊（初期災害）地点の統計量を比較すると MODEL-B および MODEL-C の値が卓越していることから、これらのモデルの有用性が確認できる。同表の降雨で生じた崩壊（二次災害）地点の平均値が大きければ、二次災害危険度推定値が精度よく表現されていることを示す。以上より、とくに MODEL-C の有用性が確認できる。

**Plate 6-1**

Slope failures

Red: found in Jan. 1995

Blue: found in Oct. 1995

White: actual photographing routes

Plate 6-2

Detected slope failures

Red: detected slope failures (Jan., 1995)-(Mar. 1993)

B/W grayscale: DTM

Plate 6-3

Detected slope failures

Blue: detected slope failures (Jan. 1995)-(Aug. 1995)

B/W grayscale: DTM

**Plate 6-4**

Slope aspect direction (clockwise degree)

Plate 6-5

Slope gradient (B: small, W: large)

Plate 6-6

Geology map

**Plate 6-7**

Seismic intensity of JMA scale 7 (500m buffering)

Plate 6-8

Active faults (500m buffering)

Fig. 6-11 は P_s を横軸にとり、これを 0.27~0.98 までの 10 段階で閾値処理し、危険地域および危険であると判断できない地域の 2 群判別を行ったときに、二次災害として生じた斜面崩壊をどの程度含むかを縦軸に百分率で示したものである。ここで、二次災害としているのは 1995 年 1 月で崩壊が確認されず同年 10 月に崩壊が確認されたものを考える。 P_s の閾値が大きいところに頻度が多く確認できれば、二次災害発生地点とその他の地点との分離度が良いことを示す。MODEL-C では P_s が 0.98 以上であれば約 30% の精度で二次災害地点を推定でき、他のモデルに比して卓越した結果が得られている。

Fig. 6-12 は横軸を Fig. 6-11 と同様の判断でとり、縦軸に P_s として得られた全画素数に対する二次災害が生じた画素の百分率を示したものである。この図も Fig. 6-11 と同様の見方ができる。すなわち、MODEL-C の災害発生箇所とその他の地域の分離性に関する有用性を確認できる。

Plate 6-12 に示されるように、航空写真を用いた対象地域の調査のための撮影コースを決定する場合、2~3 コースで危険箇所の把握ができることになる。対象地域内で時刻 t_1 に実際に航測会社が調査した撮影コース数は、1:8,000 垂直写真撮影で約 13 コースであったことから、本手法を適用することの有効性が確認できる。

6.6 結語

本章により得られた結論は、以下のように整理できる。

- ① TM データからの斜面崩壊検出手法によって得られる斜面崩壊情報には、二次災害の危険性を示す情報も含まれる。したがって、検出された情報と判読された情報の差が二次災害の危険性のある地点を表現する一つの情報と成り得る。
- ② 一般的に斜面崩壊に最も寄与する因子と考えられる地形傾斜度は、対象によっては寄与率の低い場合もある。地理情報各因子の二次災害に対する寄与率は対象とする事象および地域の特性に依存する。とくに二次災害と考えられる時間的範囲内であれば、初期災害と同様の地域で被害が多く見られることが顕著である。このことから、一般的な知見を用いて二次災害を予測することは危険であると考えられる。これらの因子は互いに影響を与えると考えられることから、ニューラルネットワークのように各因子の重みを自動的に最適化する方法により評価関数の最適化を行うことが望ましい。
- ③ 上述の評価関数により与えられる斜面崩壊危険度と斜面崩壊検出結果との論理積により与えられる情報は、精度の高い二次災害地点を与える。これにより調査等の作業の効率化が図られる。



Plate 6-9
Slope failure occurrence
probability (P_s) map
estimated by MODEL-A

Plate 6-10
Slope failure occurrence
probability (P_s) map
estimated by MODEL-B

Plate 6-11
Slope failure occurrence
probability (P_s) map
estimated by MODEL-C




Plate 6-12 Final slope failure occurrence probability map (P_s)
(logical product of P_p of MODEL-C and P_d)

← small P_s large →
White: Estimated photographing routes

第7章 結論

CHAPTER 7 CONCLUSION

本研究は地球観測衛星画像を用いて広域に分布する山地斜面崩壊を検知する手法を提案した。また、衛星データを用いた斜面災害監視GISについて新たな構想を示した。以上の成果を実際に被害のあった事例に適用し、その実用性を確認した。以下に、各章で議論した内容および得られた主要な成果を総括する。

第1章では、被災状態の把握および二次災害危険度の推定に用いるデータとして、衛星データが有効であることを示した。衛星データは、主として解像度によって瞬時視野が異なる。したがって、被災状態の把握は、瞬時視野の大きなデータから解析し、その提供情報を基にして、順次現地調査や瞬時視野の小さなデータの解析を行い、これを繰り返すことで、最終的に詳細な被災地図が完成する。衛星データが提供されるまでの時間的な問題を考えたとしても、航空写真判読の衛星データ解析に対する優位性は確認できない。また、航空写真にとって替わる高分解能衛星データの出現により、空間分解能のみをパラメータとする一貫した処理が構築されれば、小規模な自治体でも容易に災害監視が行えるものと期待される。

第2章では、災害発生直後に被災地域全域の土地被覆状態を衛星マルチスペクトルデータの多変量解析から精度良く推定する方法について示した。とくに、パターン認識に対して有効とされるニューラルネットワークについて吟味し、点環境・時刻環境が異なる対象に対しても安定した結果を出力する多層多段のニューラルネットワークを提示した。多段のニューラルネットワークによって得られる結果と多層単段のニューラルネットワーク、さらに最尤法やファジー推論と比較し、提示手法の有用性を確認できた。

第3章では、“理想的なGTデータ（教師データ）”の整備が困難な場合に、事前に整備されたGTデータの信頼性を、マルコフ確率場に基づく推移確率（因果律）から推定する方法について提示した。この信頼度に基づき土地被覆分類を行えば、全GTデータの信頼度を等しくする場合に対して、安定した結果が得られることが示された。さらに、同法をポスト処理に拡張することで、構造的に考え難い土地被覆変化を取り除くことができることが示された。ただし、この被災時における被覆変化構造を推移確率の中に取り込む必要がある。

第4章では、対象を被災地域の地形変化に限定し、この変化をセグメンテーションの観点から検出する方法について提示した。とくに、形状の取り扱いが容易なMorphologyを用いることによって、衛星データの瞬時視野の違いに対しても構成要素のサイズ n を変えるのみで対処できることを示し、WNEDを提示した。WNEDは規

則性を有する地形変化、とくに“閉じた空間”を検出する上で、細線化・ノイズ低減・サイズの拡大に伴う検出成分の肥大化抑制の面で、他の手法に比して絶大な効果があることを示した。

第5章では、対象を被災地域の山腹に限定し、斜面崩壊地点を精度良く推定する方法について提示した。衛星データと斜面崩壊面積との関係、衛星データと斜面崩壊重心からの距離との関係から斜面崩壊の状態を推定する本手法は、従来法と異なり、崩壊形状および崩壊面積を推定することができる。

第6章では、第5章までの方法によって得られる情報から、対象地域の同事象に対する二次災害発生危険度を出力する方法について示した。本方法は、従来法に対して、現地で発生した事象と現地の地理情報との関係から直後に発生が予測される二次災害の危険度を推定するものであるため、初期災害の影響を受ける時間内では危険地域を10分の1程度に絞り込むことができる。この作業に情報を逐次追加することで、徐々に精度の高い予測結果が得られるものとする。

以上の方法はLANDSAT/TMデータを用いて実行・検証された。ただし、全手法は空間分解能をパラメータとしてモデル化しているため、passiveセンサーに限らずとも、衛星データ全般に対して適用できる。今後期待される1m解像度データやSARに対して本手法の適用性が確認されれば、多面から山腹斜面崩壊をモニタリングすることでより精度の高い結果が得られるものとする。

以上のように、本研究は地球観測衛星画像を利用した広域斜面災害監視のための有効な手法を提案したものであり、その工学的意味は大きいと考える。

謝辞

ACKNOWLEDGEMENT

本研究を行うにあたり長期にわたり適切なご指導とご助言を賜った豊橋技術科学大学工学部建設工学系河邑眞助教授にお礼を申し上げます。河邑先生には、著者が大学の卒業研究で研究室の門をたたいて以来、学部および修士課程、そして福井工業高等専門学校助手、豊橋技術科学大学助手、豊橋技術科学大学と福井高専との助手併任、再び福井高専助手へと異動する慌ただししい著者を、現在に至るまで終始暖かく見守っていただきました。とくに福井高専赴任後は、200km以上もの距離を隔てた先生から心温まる激励をいただき、ともすれば校務に追われがちな著者にとって、研究を継続していく上での大きな支えとなりました。ここに、記して深甚の謝意を表します。

また、本研究の遂行にあたり、数々の有益なご示唆をいただきました豊橋技術科学工学部大学建設工学系栗林栄一教授、加藤史郎教授、大貝彰助教授には心よりお礼申し上げます。

さらに、論文の作成にあたり種々ご協力賜りました豊橋技術科学大学工学部建設工学系の諸先生方および同大学河邑研究室の学生諸氏、福井工業高等専門学校環境都市工学科の諸先生方並びにリモートセンシング研究室卒業生諸氏に深く感謝の意を表します。

六甲山系の斜面災害データの構築には神戸大学沖村孝教授、中部地区の災害履歴のデータベースの構築には愛知県、岐阜県、長野県、建設省中部地方建設局の職員の皆様をはじめ、地盤工学会中部支部平成8年、9年度の地盤工学研究委員会の委員の皆様にご協力を戴きました。ここに記して深く感謝の意を表します。

本研究の教師データの作成にあたっては、建設省国土地理院において作成された宅地動向調査に基づく細密数値情報(TDT-111, TDT-112, TDT-113)を利用しました。また、本研究で用いた衛星データは、宇宙開発事業団より1995年兵庫県南部地震に関する研究のために無償で提供されたものであります。ここに謝意を表します。

最後に、研究の進展を図るために、数度に渡り異動・転居、これに伴う雑務に協力してくれた家族・親族に感謝の意を表します。

参考文献

REFERENCES

第1章 序論

- 1-1) (財)日本建設情報総合センター, 震災対策におけるGISの有効利用, 1995.
- 1-2) 高木幹雄, 下田陽久: 画像解析ハンドブック, 東京大学出版会, 1993.
- 1-3) 河邑眞, 辻子裕二: 多段ニューラルネットワークによる人工衛星画像の土地被覆分類, 写真測量とリモートセンシング, Vol.34, No.1, 1995.
- 1-4) 清水英範, リモートセンシング画像のファジイ分類, 写真測量とリモートセンシング, Vol.31, No.4, 1992.
- 1-5) 河邑眞, Sanath JAYAMANNA, 辻子裕二: スリランカ・コロンボ市における都市化と環境変化についてのリモートセンシングデータによる分析, 第8回環境情報科学論文集, pp.117-122, 1994.
- 1-6) Makoto KAWAMURA, Sanath JAYAMANNA and Yuji TSUJIKO: A comparative study of urbanization and impact on the natural environment in Colombo city in Sri Lanka and Nagoya City in Japan using remote sensing data, Proc. of THE INTERNATIONAL SYMPOSIUM ON VEGETATION MONITORING, pp.224-230, 1995.
- 1-7) Sanath JAYAMANNA, 河邑眞, 辻子裕二: コロンボ市と名古屋市における都市化と環境変化についてのリモートセンシングデータによる比較研究, 第9回環境情報科学論文集, pp.85-88, 1995.
- 1-8) Makoto KAWAMURA, Sanath JAYAMANNNA, Yuji TSUJIKO: Relation between social and environmental conditions in Colombo, Sri Lanka and the urban index estimated by satellite remote sensing data, International archives of photogrammetry and remote sensing, vol.XXXI, part B7(commission VII), pp.321-326, 1996.
- 1-9) スリランカ・コロンボ市における人口密度・住宅密度と緑被率との関連についての考察 第10回環境情報科学論文集, pp.37-42, 1996.
- 1-10) Makoto KAWAMURA, Sanath JAYAMANNA and Yuji TSUJIKO: Relation between social conditions and the vegetation environment in Colombp city, using remote sensing data, 17th Asian conference of remote sensing, L, 3, pp.1-6, 1996.
- 1-11) 大林成行, 小島尚人, 笠博義: 斜面崩壊予測を対象とした衛星マルチスペクトルデータの実利用化について, 土木学会論文集, No.415/IV-12, pp.71-80, 1990.
- 1-12) 笠博義, 黒台昌弘, 大林成行, 小島尚人: 地すべり予測への衛星リモートセン

シングデータの応用可能性について日本リモートセンシング学会誌, Vol.12, No.1, pp.5-15, 1992.

- 1-13) 後藤恵之輔・西川麗他: 活断層の温度上昇に着目した地震予知法の開発の試み, 第15回日本自然災害学会学術講演会概要集, pp.79-80, 1996.
- 1-14) (財)日本建設情報総合センター: GIS データブック 1996 (日本の地理情報システムの紹介), 1996.

第2章 マルチスペクトルデータを用いた土地被覆状態の推定方法

- 2-1) G. E. McClellan, R. N. FeWitt, T. H. Hemmer, L. N. Matheson and G. O. Moe: Multispectral image processing with a three-layer backpropagation network, in Proc. IJCNN '89(Washington, DC), Vol.1, pp.151-153, 1989.
- 2-2) J. A. Benediktsson, P. H. Swain and O. K. Ersoy: Neural network approaches versus statistical methods in classification of multisource remote sensing data, IEEE Trans. Geosci. Remote Sensing, Vol.28, No.4, pp.540-552, July 1990.
- 2-3) H. D. Heermann and N. Khazenie: Classification of multispectral remote sensing data using back-propagation neural network, IEEE Trans. Geosci. Remote Sensing, Vol.30, No.1, pp.81-88, January 1992.
- 2-4) M. Kawamura and Y. Tsujiko: Multispectral classification of Landsat TM data using a cooperative learning neural network, in Proc. IGARSS'93, vol.2, pp.508-510.
- 2-5) 坂和正敏: ファジ理論の基礎と応用, 森北出版, 1990.
- 2-6) 古村光夫, 田中啓夫: ニューラルネットワークを用いた協調学習システムによる音声合成, 信学技報, MBE88-8, 1988.
- 2-7) 古村光夫, 田中啓夫: 多層多段のニューラルネットワークを用いた音声パターンの学習と生成, 信学論(D-II), J-73-D-II, 1990.
- 2-8) D. E. Rumelhart, J. L. McClelland and PDP Research group: Parallel distributed processing, Vol.1, MIT Press, 1986.
- 2-9) 舟橋賢一: 3層ニューラルネットによる恒等写像の近似的実現についての理論的考察, 信学論(A), J73-A, pp.130-145, 1990.
- 2-10) E. J. Green, W. E. Stawderman, T. M. Airola: Assessing classification probabilities for thematic maps, Photogram. Eng. and Remote Sensing, Vol.59, No.5, pp.635-639, 1993.
- 2-11) 建設省国土地理院: 細密数値情報(中部圏宅地利用動向調査)説明書, (財)日本地図センター, 1989.

第3章 GTデータの不整を考慮した土地被覆状態の推定方法

- 3-1) A. Benediktsson, P. H. Swain and O. K. Ersoy : Neural network approaches versus statistical methods in classification of multisource remote sensing data, IEEE Trans. Geosci. Remote Sensing, Vol.GRS-28, No.4, pp.540-552, July 1990.
- 3-2) 河邑眞・辻子裕二 : 多段ニューラルネットワークによる人工衛星画像の土地被覆分類, 写真測量とリモートセンシング, Vol.34, No.1, pp.71-80, 1995.
- 3-3) 小島尚人・大林成行 : 画像分類におけるトレーニングサンプル再抽出方法の一提案, 日本リモートセンシング学会誌, Vol.14, No.1, pp.50-65, 1994.
- 3-4) 小島尚人・大林成行 : トレーニングクラスの設定方法に関する一提案, 日本リモートセンシング学会誌, Vol.15, No.4, pp.50-65, 1994.
- 3-5) 小野徹・岡本恵二 : 土地利用図からのトレーニングデータ抽出法とその検証, 日本写真測量学会平成8年度秋季学術講演会発表論文集, pp.87-92, 1996.
- 3-6) A. Benediktsson, P. H. Swain and O. K. Ersoy : Neural network approaches versus statistical methods in classification of multisource remote sensing data, IEEE Trans. Geosci. Remote Sensing, Vol.GRS-28, No.4, pp.540-552, July 1990.
- 3-7) D. Heermann and N. Khazenie : Classification of multispectral remote sensing data using back-propagation neural network, IEEE Trans. Geosci. Remote Sensing, Vol.GRS-30, No.1, pp.81-88, January 1992.
- 3-8) 伊藤陽介・大松繁 : 競合型ニューラルネットワークによる土地被覆分類法, 写真測量とリモートセンシング, Vol.35, No.3, pp.5-17, 1996.
- 3-9) Kawamura and Y. Tsujiko : Multispectral classification of Landsat TM data using a cooperative learning neural network, in Proc. IGARSS'93, vol.2, pp.508-510.
- 3-10) Geman and D. Geman : Stochastic relaxation, Gibbs distribution, and their applications to radar images, IEEE Trans. Pattern Anal. Machine Intell., Vol.PAMI-6, pp.721-741, 1984.
- 3-11) Joen and D. Landgrebe : Classification with spatio-temporal interpixel class dependency contexts, IEEE Trans. Geosci. and Remote Sensing, Vol.GRS-30, pp.663-672, 1992.
- 3-12) H. S. Solgerg, T. Taxt and A. K. Jain : A Markov random field model for classification of multisource satellite imagery, IEEE Trans. Geosci. and Remote Sensing, Vol.GRS-34, No.1, pp.100-113, 1996.
- 3-13) J. Green and D. M. Titterton : Recursive methods in image processing, in Proc. of

- 46th Session Int. Statistical Institute, pp.1-17, 1983.
- 3-14) 天野光三 : 計量都市計画, 丸善出版, 1982.
- 3-15) H. Swain : Bayesian classification in a time-varying environment, IEEE Trans. Syst. Man. Cybern., Vol.SMC-8, pp.879-883, 1978.
- 3-16) ドニークスハルドノ・福江潔也・下田陽久・坂田俊文 : 同時生起確率行列に基づく空間的土地被覆分類におけるニューラルネットワークの利用, 写真測量とリモートセンシング, Vol.34, No.4, pp.22-35, 1995.
- 3-17) Woods : Two-dimensional discrete Markovian fields, IEEE Trans. Information Theory, Vol.IT-18, No.2, pp.232-240, 1972.
- 3-18) 建設省国土地理院 : 細密数値情報(中部圏宅地利用動向調査)説明書, (財)日本地図センター, 1989.

第4章 VNIRデータを用いた地形変化の検出方法

- 4-1) M. Haralick, S. R. Sternberg, and X. Zhuang : Image analysis using mathematical morphology, IEEE Trans. Pattern Anal. Machine Intell., Vol.9, No.4, pp.532-550, 1987.
- 4-2) 間瀬 茂, 上田 修功 : モルフォロジーと画像解析[I], 電子情報通信学会誌, Vol.74, No.2, pp.166-174, 1991.
- 4-3) 間瀬 茂, 上田 修功 : モルフォロジーと画像解析[II・完], 電子情報通信学会誌, Vol.74, No.3, pp.271-279, 1991.
- 4-4) Liang, M. Ahmadi and M. Shridhar : A morphological approach to text string extraction from regular periodic overlapping text/background images, CVGIP Graphical models and image processing, Vol.56, No.5, pp.402-413, 1994.
- 4-5) Kawamura, S. Jayamanna and Y. Tsujiko : An analysis of urbanization and environmental change in Colombo, Sri Lanka using remote sensing data, Papers on Environmental Information Science, No.8, pp.117-122, 1995.
- 4-6) 磯部 義明, 大久保なつみ, 他3名 : 孤立性陰影検出用 Quoit フィルタの性質とその乳癌 X 線陰影検出への応用, 電子情報通信学会誌, D- II, Vol.J76-D- II, No.2, pp.279-287, 1993.
- 4-7) Y. Shih, C. T. King and C. C. Pu : Pipeline architecture for recursive morphological operations, IEEE Trans. Image Processing, Vol.4, No.1, pp.11-18, 1995.
- 4-8) Park and R. T. Chin : Decomposition of Arbitrarily Shaped Morphological Structuring Elements, IEEE Trans. Pattern. Anal. Machine Intell., Vol.17, No.1, pp.2-15, 1995.

- 4-9) Maragos and R. W. Shafer : Morphological filters-Part I, IEEE Trans. Acoust. Speech Signal Processing, Vol.35, No.8, pp.1156-1169, 1987.
- 4-10) Maragos and R. W. Shafer : Morphological filters-Part II, IEEE Trans. Acoust. Speech Signal Processing, Vol.35, No.8, pp.1170-1184, 1987.
- 4-11) Y. Chang : Distance transformation in digital images, Comput. Vision, Graphics, Image Processing, Vol.34, pp.344-371.
- 4-12) Kawamura and Y. Tsujiko : An approach to geographic pattern recognition using Mathematical Morphology, IGARSS'94, 1994.
- 4-13) A. Peters : A new algorithm for image noise reduction using mathematical morphology, IEEE Trans. Image Processing, Vol.4, No.5, pp.554-568, 1995.
- 4-14) Krishnamurthy, S. S. Iyengar, R. J. Holyer and M. Lybanon : Histogram-based Morphological edge detector, IEEE Trans. Geoscience And Remote sensing, Vol.32, No.4, pp.759-767, 1994.

第5章 IR データを用いた山腹斜面崩壊の面積・形状の推定方法

- 5-1) 沖村孝 : 土木学会阪神大震災震災調査第二次報告会資料, 社団法人土木学会, pp.163-168, 1995.
- 5-2) 大林成行・小島尚人・笠博義 : 斜面崩壊予測を対象とした衛星マルチスペクトルデータの実利用化について, 土木学会論文集, No.415/IV-12, pp.71-80, 1990.
- 5-3) 笠博義・黒台昌弘・大林成行・小島尚人 : 地すべり予測への衛星リモートセンシングデータの応用可能性について日本リモートセンシング学会誌, Vol.12, No.1, pp.5-15, 1992.
- 5-4) 後藤恵之輔・瀬戸島政博・深津信義・岡島修平 : リモートセンシングによる斜面崩壊発生地点の予測手法, 土質工学会論文報告集, Vol.25, No.2, pp.185-194, 1985.
- 5-5) 上林徳久・石森繁樹 : 衛星画像による地すべり地判読, 日本リモートセンシング学会誌, Vol.10, No.3, pp.93-99, 1990.
- 5-6) 島担 : 衛星画像からみた地すべり発生地の分布, 日本リモートセンシング学会第9回学術講演会概要集, pp.35-36, 1991.
- 5-7) R. M. Haralick, S. R. Sternberg, and X. Zhuang : Image analysis using mathematical morphology, IEEE Trans. Pattern Anal. Machine Intell., Vol.9, No.4, pp.532-550, 1987.
- 5-8) 河邑眞・辻子裕二 : Landsat/TM による河川境界検出手法に対する多重

- Morphology 解析の応用, 写真測量とリモートセンシング, Vol.35, No.5, pp.36-45, 1996.
- 5-9) 富田陽子, 桜井恒, 中傭充 : 六甲山系における時震度の降雨による崩壊地の拡大について, 新砂防, Vol.48, No.6 pp.15-21, 1996.
- 5-10) 仲野公章, 富田陽子, 桜井恒 : 兵庫県南部地震後の六甲山系における土砂災害ソフト対策, 新砂防, Vol.48, No.4, pp.58-62, 1995.
- 5-11) 吉澤孝和・酒井輝雄・宮野尾文夫・根岸六郎・関貴幸 : 空中写真測量による地下すべり面形状解析システム, 写真測量とリモートセンシング, Vol.33, No.3, pp.17-32, 1994.
- 5-12) 吉澤孝和 : 地上測量による地下すべり面の形状および地すべり影響圏の推定, 地すべり, Vol.26, No.3, pp.28-39, 1989.
- 5-13) David J. Varnes : Slope Movement and Types and Process in Landslides, 1978.
- 5-14) 武居有恒 : 地すべり・崩壊・土石流, 鹿島出版会, pp.147-153, 1982.
- 5-15) 平野昌繁 : 斜面発達とくに断層崖発達に関する数学的モデル, Vol.39, pp.324-336, 1966.

第6章 リモートセンシングデータを用いた災害監視GIS

- 6-1) 田村俊和 : 地震により表層滑落型崩壊が発生する範囲について, 地理学評論, 51-8, pp.662-672, 1978.
- 6-2) 安田進・杉谷俊明 : 地震時斜面崩壊履歴の調査, 第23回土質工学研究発表会発表概要集, pp.891-892, 1988
- 6-3) Keefer D. K. and Wilson R. C. : Predicting Earthquake-Induced Landslide with Emphasis on arid and Semi-Arid Environments, Publication of Inland Geological Society, Vol.2, pp.118-149, 1989.
- 6-4) Ishihara K. and Nakamura S. : Landslides in Mountain Slopes during the Ecuador Earthquake of March 5, 1987, US-Asia Conference on Engineering for Mitigating Natural Hazard Damages, 1987.
- 6-5) Mora S. and Mora R. : Landslides triggered by the Limon-Telie Costa Rica Earthquake and comparison with other events in Costa Rica, U. S. Geological Survey Professional Paper, 1993.
- 6-6) Wilson R., Eieczorek G. and Harp E. : Development of critical for regional mapping of seismic slope stability, 1979 Annual Meeting of the Geological Society of America, 1979.

- 6-7) Siyahi G. B. and Ansal A. M. : Slope stability by Koppula method, Personal Communication, 1993.
- 6-8) Koppula S. D. : Pseudo static analysis of clay slopes subjected to earthquakes, Geotechnique, Vol.34, No.1, pp.71-79, 1984.
- 6-9) 亀田・碓井照子 : 例えば, 1995 年兵庫県南部地震による西宮市の都市施設被害の多重分析, 第 15 回自然災害学会学術講演会概要集, pp.71-72, 1996.
- 6-10) (財) 日本建設情報センター : 震災対策における GIS の有効利用, 1995.
- 6-11) 大林成行・小島尚人・笠博義 : 斜面崩壊予測を対象とした衛星マルチスペクトルデータの実利用化について, 土木学会論文集, No.415/IV-12, pp.71-80, 1990.
- 6-12) 笠博義・黒台昌弘・大林成行・小島尚人 : 地すべり予測への衛星リモートセンシングデータの応用可能性について, 日本リモートセンシング学会誌, Vol.12, No.1, pp.5-15, 1992.
- 6-13) 後藤恵之輔・瀬戸島政博・深津信義・岡島修平 : リモートセンシングによる斜面崩壊発生地点の予測手法, 土質工学会論文報告集, Vol.25, No.2, pp.185-194, 1985.

