

2007年度 修士論文

衛星画像および既存の土地被覆図の組合せによる  
全球都市域マッピング手法に関する研究  
Study on Automatic Global Urban Mapping Method  
using Satellite Imagery and the Existing Land Cover Data

田中 絢子  
Tanaka, Ayako

東京大学大学院新領域創成科学研究科  
環境学研究系 社会文化環境専攻

# 目次

第 I 章 序論	2
I-1 はじめに	3
I-2 目的	6
I-3 都市域の定義	7
I-4 既存都市域データと本研究の位置づけ	8
I-5 本論文の構成	9
第 II 章 データソース	10
II-1 利用データの特徴比較	12
II-1.1 ASTER 画像	14
II-1.2 GRUMP/urban extent (Global Rural Urban Mapping Project)	14
II-1.3 MOD12 土地被覆図	15
II-2 対象都市	16
第 III 章 都市域マッピング手法	18
III-1 都市域マッピング手法の構成と手法の自動化	19
III-2 目視判読による検証データの作成	21
III-3 データ処理過程の検討	21
III-3 データ処理過程の検討	22
III-3.1 既存データの加工	22
III-3.2 ASTER 画像分類	23
III-3.3 ベイジアンネットワークモデルを用いた条件付確率の計算	27
III-3.4 都市域マッピング	28
III-4 精度検証方法	28
第 IV 章 検証	30
IV-1 既存データの加工	31
IV-2 ASTER 画像分類	33
IV-3 ベイジアンネットワークモデルを用いた条件付確率の推定	37
IV-4 都市域マッピング	38
IV-4 都市域マッピング	39
IV-5 考察	42
第 V 章 結論と今後の展望	46
V-1 結論	48
V-2 今後の展望	48
参考文献	51
謝辞	53
付録	57



# 第 I 章 序論

## I-1 はじめに

近年、地球温暖化による海面上昇や熱波・巨大ハリケーンの発生など気候変動による人間活動への影響が深刻化しており、地球規模での分析が急務となっている。IPCCの第二作業部会<sup>1</sup>の報告書によると、上昇気温別の被害予測が詳細に記されており、食糧(農業・漁業)・海面上昇・健康など人間活動を支える重要な資源に対するリスクが明らかにされた。本報告書では、気候変動の被害は工業化された先進国ではなく、特にアフリカ・アジアの途上国から始まると述べている。

例えば、南太平洋の島国では、地球温暖化が原因とみられる海面上昇などにより数多くの「環境難民」が発生している。国連環境計画(UNEP)は2005年にバヌアツ諸島の一部で気候変動による「環境難民」が発生したことを明らかにした。難民となったのは沿岸地域の住民で、気候変動の影響で嵐や津波が多発し住居がたびたび浸水していることから、2005年8月までに100人以上が内陸部の高地に移住した。ヒマラヤなどの高山地帯でも氷河の溶解により難民発生のおそれがあるという。政治・戦争による難民の数は2300万人とされているが、環境難民といわれる人々は既に2500万人を超えているとされ(UNEP, 1998)、深刻な社会問題となりつつある。

また、感染症の拡大など健康面での被害も深刻化する恐れがある。都市化の90%は途上国で進んでいるとされているが、途上国では人口成長に対応したインフラストラクチャーの整備が十分であるとは言えず、気候変動による深刻な健康被害を引き起こす可能性がある。

このように、特に途上国における被害分析が重要であると考えられているにも関わらず、IPCCの第二作業部会の報告書に示されたデータは「地球全体では均等な精度とは言えず、特に途上国におけるデータの精度は十分とは言えない」としている。

現在、様々な機関が様々な方法で被害予測などの研究を進めているが、中でも地理空間情報の利用は、空間的な被害分布を視覚的に表現することができるため、有効な分析手法のひとつであるといわれている。アジェンダ21<sup>2</sup>においても、地球環境の現状を理解し、気候変動モニタリングを行うのに地理空間情報の整備が重要な施策の一つにあげられている。

多くの地理空間情報の中でも、都市域データは人間活動に対する様々な影響を分析する上で非常に重要なデータのひとつであるといえる。

過去数十年間、都市域の拡大・都市への人口集中が進行し続けている。都市域は地球上の陸地面積のごく一部を占めるにすぎないが、世界の人口の約半数は都市部で生活をして

---

<sup>1</sup> IPCC : Intergovernmental panel on climate change (気候変動に関する政府間パネル)の第2作業部会(WokingGroup2)は生態系、社会・経済等の各分野における影響及び適応策についての評価を行う。つまり、気候変動がどのようなインパクトを与えるかをまとめるグループであり、自然あるいは人間社会への影響などを評価する。

<sup>2</sup> アジェンダ21 : 1992年の国連環境開発会議(地球サミット)で決議された、持続可能な発展を実現するための具体的なアクション・プログラム

おり(国連, 2001), 都市域の拡大や都市域人口の増加が, ローカルからグローバルな規模に至るまで, 社会や環境に対する大きな影響を与えるようになっている(Sherbinin et al, 2002). こういった状況の下, 気候変動による被害が人間活動域にどう影響を及ぼすかを空間的に把握することが重要視されているが, それには, 各被害予測の地理空間情報に都市域データおよび人口データを重ね合わせるのが有効である. データの重ね合わせにより, どの都市にどの程度の影響が起り得るかを視覚的に把握することができるためである.

例えば, 図 1.1 のように, Guerra らは地理空間情報を用いてグローバルなマラリア感染リスクの分析を行っている. この研究では, 分析のためのデータソースとしてグローバルな都市域データのひとつである Global Rural Urban Mapping Project(GRUMP)の urban extent データを利用している.

また, 図 1.2 のように, McGranahan らは地球温暖化による海面上昇など気候変動による被害を最も受けやすい海岸沿いの低地の分布や人口を分析している(McGranahan, et al, 2007). こちらの研究においても, 都市域空間分布データのひとつである GRUMP/urban extent をデータソースとして利用している.

このほかにも, 二酸化炭素の吸収・放出を陸域生態系モデルに基づいて高精度に推定する場合, 現在は各種土地被覆図が利用されているが, モデルの精度の向上に伴い, 土地被覆図の各カテゴリの精度向上への要求が高まっている. 「都市」カテゴリも森林などのカテゴリと同様に精度の向上が望まれるカテゴリのひとつである.

人間の主要な活動域である都市域および都市化地域の空間分布を表すデータはこのように様々な分野において利用されており, 都市化地域の空間データや時系列変化のデータを整備することは非常に重要であるといえる. しかしながらグローバルな都市域の空間分布データは十分整備されているとはいえない状況にある.

例えば, グローバルな都市域データの例として, 夜間光を捉えた観測データから都市域を抽出した Defense Meteorological Satellite Program Operational Linescan System (DMSP-OLS)/stable night-light data や, UMD(現 NIMA)により作成された Digital Chart of the World(DCW:1993)の"population place"ポリゴンデータ, DMSP-OLS にセンサスデータなどを組合せてデータを改良した Grobal Rural Urban Mapping Project(GRUMP :Balk et al., 2004)/urban extent grid などがある.

これらのデータの分解能は, DMSP-OLS が 2.7km 分解能, GRUMP/ urban extent では 1km の分解能であり, 詳細な都市域データとはいえない状況にある. また, 現在も都市域データとして利用されている DCW は, 1993 年のデータであり, 急激に都市域の拡大が進んでいる現状に則したデータであるとはいえない. つまり, グローバルな都市域の空間データは空間分解能や精度の面で十分に整備されているとはいえず, より高品質なデータの整備が望まれている.

そこで, 本研究では, 既存のデータと比較して分解能・精度の高いグローバルな都市域空間データを, 自動的に作成することを目標とした都市域マッピングシステムを設計する.

まず、問題点のひとつであった分解能の改善のため、分解能の高い ASTER 画像の利用を試みる。

近年、分解能の高いセンサを搭載した衛星は数多く存在するが、全球の都市域データを作成するためにはグローバルアーカイブの完成している衛星画像を利用する必要がある。しかしながら、高分解能衛星では全球データが揃っていない場合が多く、また、全球のデータを手に入れようとすると高分解能衛星画像ほどデータ量が膨大になり、データ処理能力や入手コストの面でも障壁が高くなる。そこで、今回は可視近赤外領域において 15m の分解能を持ち、既にグローバルアーカイブが完成しており、さらにコスト面でも比較的安価に入手可能である ASTER 画像を利用して全球の都市域マップを作成することとした。

ASTER 画像の全球処理を行う場合、膨大なデータ量を扱うこととなるため、全ての過程において全自動での処理が可能となり、なおかつ既存の手法を用いたできるだけ簡単な処理で、ある程度の精度を持った都市域マップを作成できるような手法を考案することが望ましい。一点注意する必要があるのは、全球の画像を全て同様の手法で分類するのは困難であるということである。なぜなら、全球の衛星画像分類を行う場合、気候や地形条件、画像取得時の状況など条件の異なる様々な都市の様々な画像を扱うこととなるため一律に同じ手法で都市域の分類を行った場合都市域の抽出精度に差が出るのが予想されるためである。そこで、都市域周辺の植生がその分類精度に大きな影響を及ぼすという仮定のもと、ケッペンの気候区分も考慮することのできる手法を構築することが望ましい。

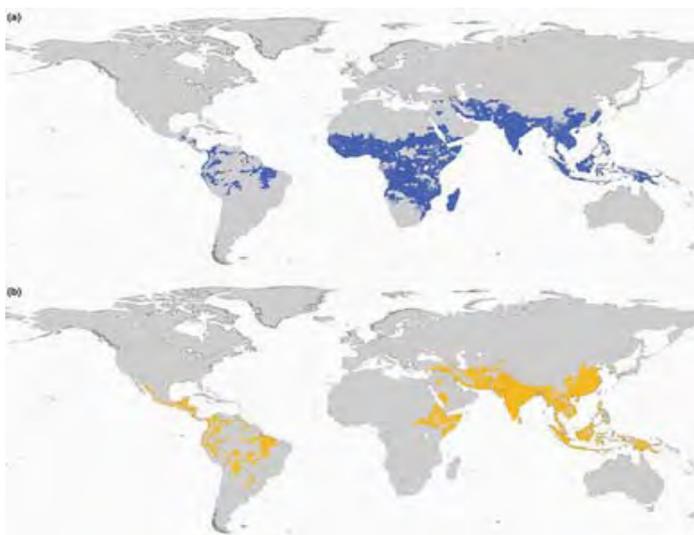


図 1.1 マラリア感染リスクマップ(Guerra et al, 2005)  
 (a) 熱帯熱マラリア原虫 (b)三日熱マラリア原虫



図 1.2 海岸沿い低地における人口密度マップ (McGranahan, et al, 2007)

## I-2 目的

本研究では、全球の都市域を自動的に、かつ精度よくマッピングすることが最終的な目標である。そこで、自動的かつ精度のよい全球都市域マッピングに適した手法(図 1.3)を提案し、テストエリアにおいて提案された手法の精度検証を行った。

衛星画像から都市域を抽出し、抽出結果と既存の都市域データ・土地被覆図を組み合わせることにより精度の向上を、GIS ソフトのひとつである GRASS およびスクリプト処理を用いることにより手法の自動化を図り、全球スケールの都市域マッピング手法を構築することとした。

全球をカバーするアーカイブが既に完成しており、かつ解像度の高い ASTER 画像、夜間光データをベースとしたグローバルな都市域データであり、直接的に人間活動域を拾っている GRUMP/urban extent, 土地被覆図の中で精度がよいとされている MOD12/urban and built-up の3つのデータをデータソースとして利用する。

さらに、全球処理を行うにあたって、膨大なデータ量を扱うことになるため、できる限り簡単なシステムで高精度に都市域マッピングができるとよい。そこで、各過程においては既存の分類手法を利用し、全自動都市域マッピングシステムを構築する。

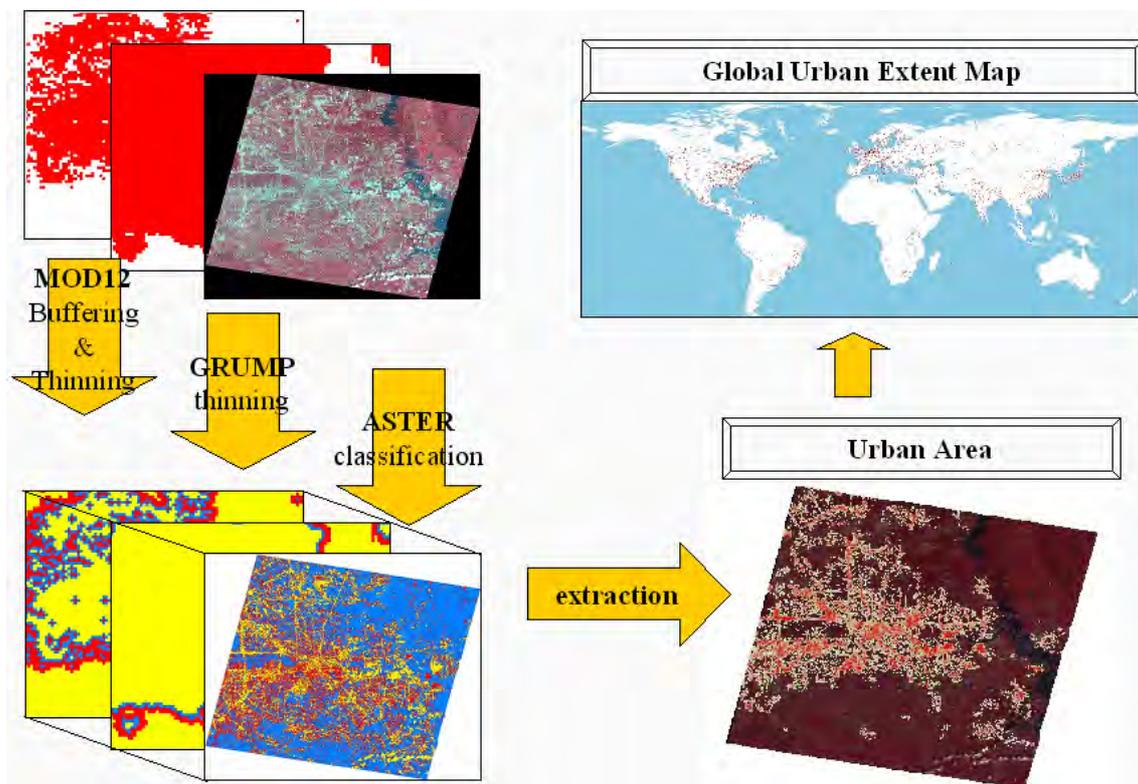


図 1.3 都市域マッピング

### I-3 都市域の定義

本研究では、人工物によって覆われた空間を「都市域<sup>3</sup>」として定義した。都市域マッピングにあたり、最も重要なことのひとつが「都市域」の定義である。都市を一義的に定義することは困難であるが、現段階では本手法を用いた全球都市域データについては海面上昇による居住域への被害推定や土地被覆図の精度向上に向けた利用など多目的な利用を想定している。そこで、本研究では人間居住域および人工的に手が加えられた地域、つまり都市域および都市化地域<sup>4</sup>を「都市域」としてマッピングすることとした。衛星画像分類では、土地被覆を分類することができるが、これらの地域はどちらも人工的な土地被覆であると考えられるため、本研究では人工物によって覆われた空間を「都市域」と定義し、マッピングすることとした。

本研究のように、多目的に活用される基盤データを作成することを目的とする場合、明確に都市を定義してしまうとその目的以外の用途には使えないデータとなってしまう。都市の一側面を捉えた定義は無数にあるが、すべての時代のすべての都市の局面を包括的かつ簡潔に定義することはほとんど不可能に近い。

そこで、ここでは既存の土地被覆図における「都市」に対応するカテゴリの名称を確認し、表〇にまとめた。圧倒的に“urban and built-up”という定義が多く、「都市空間および市街地(建て込んでいる地域)」を都市と捉える場合が多いことがわかった。

表 1 土地被覆図における「都市」

土地被覆データ名称	データ作成元	都市カテゴリの定義
GLC2000	Joint Research Center, EU	Artificial surfaces and associated areas 人工的な土地被覆とその関連地域
MOD12	Boston Univ., US	Urban and Built-Up 都市域および密集市街地
UMD Global Land Cover Classification (GLCF)	University of Maryland, US	Urban and Built 都市域および密集市街地
GLCC	The U.S. Geological Survey's (USGS) National Center for Earth Resources Observation and Science (EROS)	Urban and Built-Up Land 都市域および密集市街地

<sup>3</sup> マックス・ウェーバーは著書「都市の類型学」において、以下のように述べている。

「すべての都市に共通しているものはただ次の一事にすぎない。すなわち、都市というものは、とにかくひとつの（少なくとも相対的に）まとまった定住一ひとつの集落一であり、ひとつまたは数個の散在的住居ではないということである。(Weber, 1964:3)

都市：『都市の類型学』マックス・ウェーバー(Max Weber)

<sup>4</sup> 「都市化」の概念は、初め社会学において登場し、「農村社会が都市社会へ変質する過程」がその中心としてとりあげられている。社会学以外では、たとえば都市の代表的な指標が人口であることから、人口学では「工業化により労働力人口が集積する過程」としてとらえているし、都市を地域現象としてとらえる地理学では、「近代産業の発展によって rural な地域が urban な地域へ変質する過程」とする概念規定などがある。このほかにも多くの学問分野で固有の都市化の規定が試みられているが、そのいずれも都市化を「非都市的な状態が都市的な状態へ変化してゆく過程」としている点では共通している。

#### I - 4 既存都市域データと本研究の位置づけ

衛星から取得されたデータを利用して作成されたグローバルな都市域マップの中でも最も有名な例のひとつが、アメリカ空軍の管理する衛星であるDMSP(Defense Meteorological Satellite Program)に搭載されたセンサOLS(Operational Linescan System)により取得された夜間光データを元に作られたDMSP-OLS/ stable night-right dataである。図1.4は、DMSP-OLSのstable night-lightデータによる都市域マップである。DMSP-OLSのstable night-lightを抜き出すことにより、比較的正確で経済的に、かつ直接的にグローバルな都市域空間をマッピングする方法が示された。しかしながら、このDMSP-OLSの都市域データの空間分解能は2.7kmと非常に粗く、さらに都市域面積が過大評価される“blooming”と呼ばれる現象が確認されている。“blooming”の影響を取り除くために閾値処理(thresholds)を行った場合、小集落の抽出ができなくなってしまうため位置精度と分類精度をともに改善することは困難である(Small et al., 2005)。また、都市の面積と光の強さの関係は、その都市のエネルギー消費や経済成長、住宅の密度などにも影響を受けるため、DMSP-OLSデータにおける都市部の面積と実際の面積との間に明確な関連は見受けられない。

また、都市域データの有名な例のひとつに、DCW(Digital Chart of the World : 1993)のPopulated Placeがある。DCWは、1:1,000,000スケールで整備された全球規模の基礎的地理データで、U.S. DMA(Defense Mapping Agency, 現NIMA: National Imagery and Mapping Agency, Dept of Defense)のOperational Navigation Chart (ONC)をデータソースとして作られたベクター型のデータセットである。DCWにはPopulated Place layerというレイヤが整備されており、都市域がポリゴンデータで表現されている。現在でも都市域の全球データセット作成に利用されることが多い。しかし、近年都市域が拡大の一途をたどっているにも関わらず、このデータは15年前につくられた1993年版が最新版であり、近年の都市域とは一致しない部分が多くなっている。

このほかに、GRUMP(Global Rural Urban Mapping Project)によるurban extent gridという1km分解能の都市域データがある。DMSP-OLSをデータソースとして利用しているため、“blooming”の影響により、面積が過大評価となっているが、センサデータなどを組み合わせることにより、DMSP-OLSと比較するとデータの精度および分解能に向上が見られる。

このように衛星から取得された画像からの都市域マッピングは比較的古くから行われてきた。また近年、高分解能衛星が次々と打ち上げられる中、高解像度衛星画像を用いた都市研究は近年積極的に行われている。しかしながら、ローカルな都市域抽出およびその地域における都市域抽出精度の向上を目標とする研究がほとんどであり、全球レベルでの都市域抽出を目的とした衛星画像分類による都市域マッピング手法の自動化および精度検証はほとんどおこなわれていない。



図 1.4 DMSP-OLS stable night light data

出典：<http://svs.gsfc.nasa.gov/goto?2916>

## I - 5 本論文の構成

第II章では自動的な都市域マッピングのデータ処理の流れおよび精度検証方法について論ずる。ここではまず、利用する衛星画像データおよび既存の都市域マップにおける、それぞれのデータの仕様・特徴について言及する。さらに研究都市の選択方法と選択された都市について説明し、研究方法および精度検証方法について論ずる。

第III章では、各コンポーネントの検討結果および分類結果の精度について論ずる。ここではまず、第II章で提案された各手法を比較し、それぞれの利点・欠点について言及し、適切なアルゴリズムを提案する。さらに、提案された手法によって得られた都市域抽出結果について精度検証を行い、提案された手法の利点・欠点について言及する。

第IV章では、本研究の結論および今後の課題について述べる。

## II章 データソース



## II-1 利用データの特徴比較

本研究では、衛星画像のひとつである「ASTER 画像」、グローバルな都市域データのひとつである「GRUMP/urban extent」、グローバルな土地被覆図のひとつである「MOD12」の3種類のデータを利用する。

ASTER データは VNIR(Visible and Near Infra-Red : 可視・近赤外域波長帯)において 15m の高い分解能を持ち、かつ図 2.3 の取得シーンマップのとおり、既にグローバルなアーカイブが完成しているため、高分解能でグローバルな都市域の抽出を行うのに有効なデータである。ASTER センサの主要諸元を表 2.1 に、可視・近赤外放射計の諸元を表 2.2 に示した。ASTER 画像単独の画像分類により都市域を分類した場合、分解能の向上が期待でき、都市域の境界を細かく定義することができるという利点がある。しかしながら、単独画像の分類では、多くの誤分類が発生する。例えば、ASTER 画像は高解像度衛星であるため、時系列データが揃うとは限らない。このため水田を都市として誤分類してしまうなど、季節変化<sup>5</sup>による誤分類が発生してしまう。また、衛星データのみでの都市域分類では雲や裸地、山陰を都市として誤分類してしまうなどの欠点があった。これらの影響を取り除くため、GRUMP と MOD12 を補助的に組み合わせることとした。

GRUMP/ urban extent は、グローバルな都市域データのひとつであり、夜間光データをベースとしているため、直接的に人間活動域を特定しているデータであると言える。

MOD12 は、グローバルな土地被覆図のひとつであり、土地被覆図の中でも特に精度が高い<sup>6</sup>ことが知られている。カテゴリのひとつとして、urban and built-up というカテゴリが設定されており、このカテゴリのみを抜き出すことで人間活動域の空間データとして扱うことが可能である。

それぞれのデータの特徴を表 2.3 にまとめた。「異なる特徴を持つデータの組合せにより、それぞれのデータの長所が他のデータの短所を補完すると考えられるため、都市域抽出精度が改善される」という仮定のもと、これらのデータを組み合わせることとした。

表 2.1 ASTER センサ主要諸元

ASTER 主要諸元			
観測波長帯	可視・近赤外域	3バンド+後方視	0.52~0.86 $\mu$ m
	短波長赤外域	6バンド	1.60~2.43 $\mu$ m
	熱赤外域	5バンド	8.125~11.65 $\mu$ m
地表分解能	可視・近赤外域		15m
	短波長赤外域		30m
	熱赤外域		90m
Radiometric分解能	可視・近赤外域	NE $\Delta$ $\rho$	$\leq 0.5\%$
	短波長赤外域	NE $\Delta$ $\rho$	$\leq 0.5\%$ ~1.5%
	熱赤外域	NE $\Delta$ T	$\leq 0.3K$
地表走査幅			60km
ポインティング角度範囲 (但しVNIRは)			$\pm 8.55^\circ$ $\pm 24^\circ$
B/H比(軌道内後方視による)			0.6

表 2.2 可視・近赤外放射計 主要諸元

VNIR 諸元		
観測波長帯	バンド1	0.52~0.60 $\mu$ m
	バンド2	0.63~0.69 $\mu$ m
	バンド3	0.76~0.86 $\mu$ m
立体視バンド	0.76~0.86 $\mu$ m	後方視
地表分解能		15m
Radiometric分解能		0.5%NE $\Delta$ $\rho$
ポインティング角度範囲(軌道方向と直角)		$\pm 24^\circ$
瞬時視野角		21.3 $\mu$ rad(直下視) 18.6 $\mu$ rad(後方視)
検出器		5,000画素CCD

<sup>5</sup> 季節変化： 落葉性の植物に見られるような一年周期の変化。農地ではこの変化が明瞭に現れる。「図解リモートセンシング」

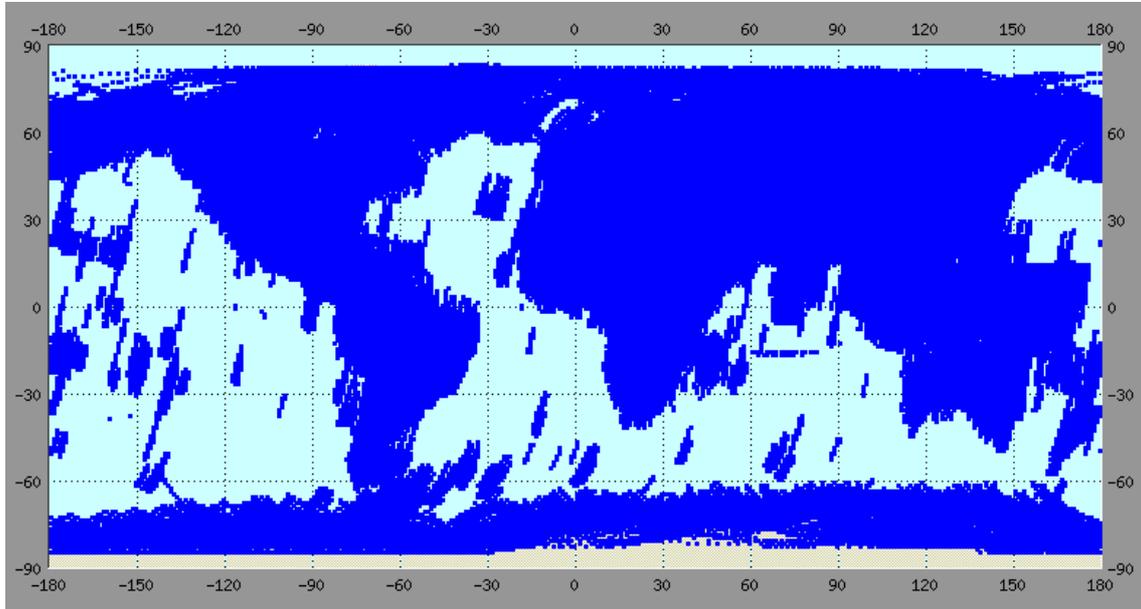


図 2.1 ASTER 取得シーンマップ

表 1.3 データソースの特徴比較

	ASTER画像	GRUMP/ urban extent	MOD12/ urban and built-up
分解能	可視・近赤外バンド:15m	1km	1km
特徴	グローバルなアーカイブ 高分解能 季節変化を追うことができない ASTER画像単独分類結果:誤分類が発生	夜間光データがベース 直接的に人間活動域を拾い出す 分解能が低い "blooming"による面積の過大評価	MODIS時系列データを用いた土地被覆図 季節変動を考慮した分類 分解能が低い 小都市の位置精度

<sup>6</sup> 土地被覆図の精度は、GLC2000 : 55%, MOD12 : 58%, UMD : 54%, GLCC : 50%

## II - 1. 1 ASTER 画像

ASTER (Advanced Spaceborne Thermal Emission and Reflection radiometer) センサは、人工衛星TERRA に搭載されているセンサのひとつであり、地球科学の様々な分野において活用される画像データを取得している。ASTER センサは可視バンドから熱赤外バンドまでの14スペクトラムチャンネルを有する光学センサで、後方視バンドを含め15バンドの画像情報を取得する。ASTERセンサは、以下の3つの放射計から構成されており、ASTERの主要諸元およびVNIR放射計の諸元は表○および○に示したとおりである。

- ・可視近赤外放射計 (VNIR : Visible and Near-infrared Radiometer)
- ・短波長赤外放射計 (SWIR : Short Wave Infrared Radiometer)
- ・熱赤外放射計 (TIR : Thermal Infrared Radiometer)

ASTER センサは、近赤外バンドでは、後方視を利用することにより、同一軌道で立体視画像を取得することができるため、ASTERからDEMデータが作成されている。

本研究では分解能の向上を図るため、解像度が15mと最も高い、可視近赤外域の画像データを利用することとした。

## II - 1. 2 GRUMP/ urban extent (Global Rural Urban Mapping Project)

GRUMP(Global Rural Urban Mapping Project)/ urban extent は、コロンビア大学のCIESIN (Center for International Earth Science Information Network)によって作成された都市域の分布を表す空間データである(図 2.2)。

GRUMP は、オンラインで作成データを配布しており、バイナリデータやアスキー形式などのデータフォーマットが用意されている。分解能は 30arc-second メッシュ、約 1km 分解能となっている。DMSP-OLS 同様、面積が過大評価となっているという特徴がある。GRUMP は都市域の空間データに加え、分解能の同じ人口データも作成している。

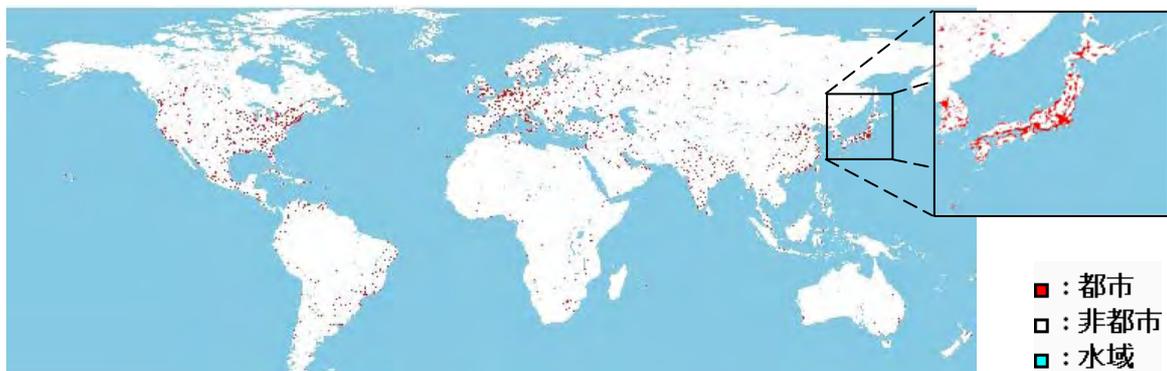


図 2.2 GRUMP/ urban extent – GLOBAL

## II-1.3 MOD12 土地被覆図

MOD12 は、MODIS 画像の時系列データの教師つき分類により作成された土地被覆図である。都市域は：urban and built-up カテゴリに対応する。既存の土地被覆図の中では精度が高く(岩男,2007), 時系列データを利用していることから, 季節変化による影響がとり除かれたデータとなっている。分解能は 1km となっている。GRUMP と同様にオンラインで配布されており, 図 2.4 のような全球土地被覆図として入手することができる。

MOD12は, 図 2.4にあるように 16 のカテゴリを持つ土地被覆図である。このうち urban and built-up のカテゴリを抜き出したものが図 2.3 である。GRUMP と比べるとやや面積が小さく定義されていることが分かる。

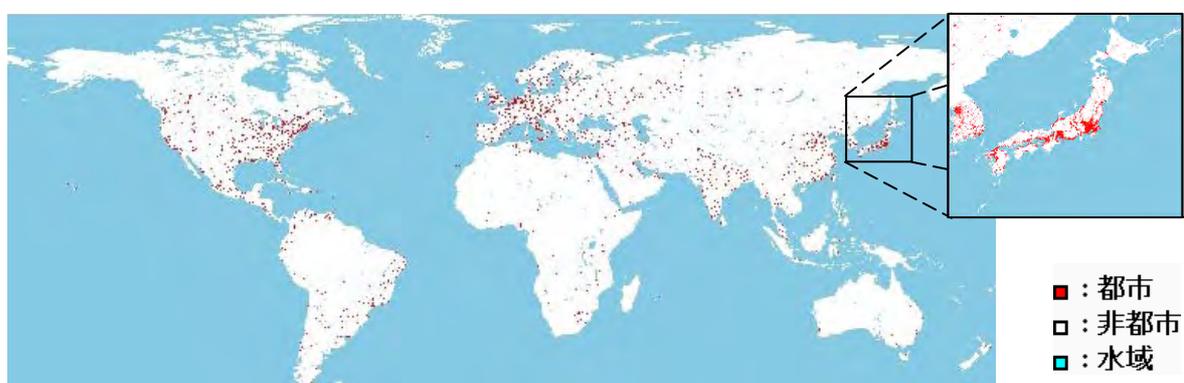


図 2.3 MOD12/ urban and built-up

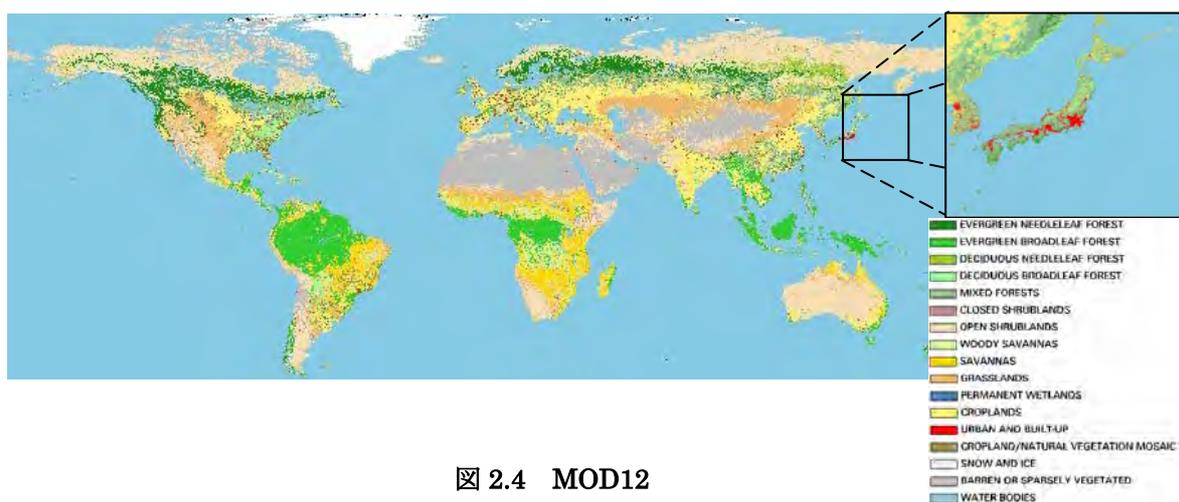


図 2.4 MOD12

<http://geography.bu.edu/landcover>

## Ⅱ－２ 対象都市

100 都市を対象都市として選択し，対象都市の分布を図 2.5 に示した．

初めに，各気候帯において，GRUMP および MOD12 で都市域とされたポリゴン数をカウントし，気候帯別都市ポリゴン数の比率を算出した．

次に，気候帯別都市ポリゴン数の比率を保った状態で合計が 100 都市となるように各気候帯におけるサンプル数を決定した．

各気候帯における都市ポリゴン数および選択都市数は表○に示したとおりである．

続いて，各気候帯に属す都市ポリゴンの中から，サンプル数の都市ポリゴンをランダムに選択し，対象都市とした．

都市は圧倒的に温帯地域に多く分布していた．

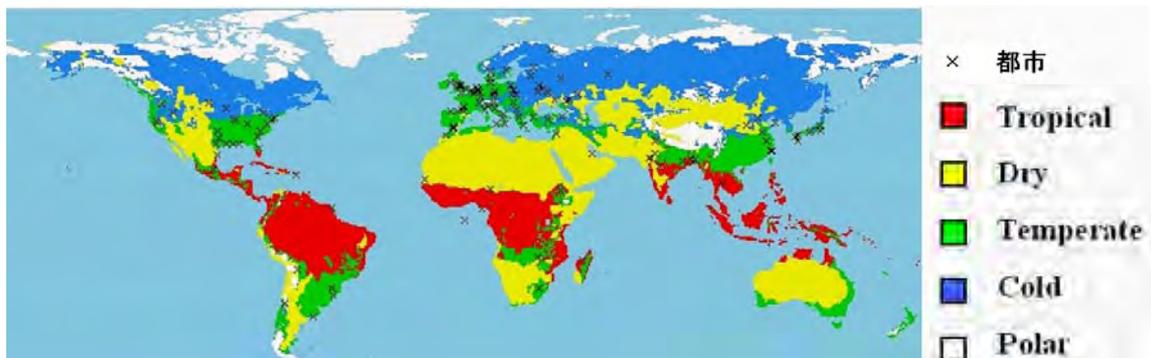


図 2.5 対象 100 都市



## Ⅲ章 都市域マッピング手法

### Ⅲ-1 都市域マッピング手法の構成と手法の自動化

本研究では、初めに図 3.1 のように大まかなデータ処理の手法を設定し、自動化を行った。自動化にあたって、スクリプト処理により大量のデータを簡単に処理することが可能であるため本手法全体を通して GIS ソフトの GRASS, OS は Linux(open-SUSE)を用いた。

本システムは「確率テーブル作成部」および「データ処理部」からなる。「確率テーブル作成部」はデータ処理部で用いる確率テーブルを作成することを目的としており、「データ処理部」は実際に都市域を抽出し、都市域をマッピングすることを目的としている。

「確率テーブル作成部」では、始めに対象都市の検証用データを作成する。各画像中に約 500 点のポイントを発生させ各ポイントの目視判読を行い、これを検証用データとして利用する。

次に、buffering あるいは thinning により GRUMP/urban extent および MOD12/urban and built-up を加工する。続いて ASTER 画像の都市域分類を行い、ASTER 画像から分類した都市域データと加工済み既存都市域データをオーバーレイした。さらに、重ね合わせにより得られたそれぞれのデータの組合せについて、ベイジアンネットワークモデルを用いてそれぞれが都市域である確率を推定することにより確率テーブルを作成した。

「データ処理部」では、始めに確率テーブル作成部同様、対象都市の検証用データを作成する。次に確率テーブル作成部と同様の方法で buffering あるいは thinning により GRUMP/urban extent および MOD12/urban and built-up を加工する。ひき続き ASTER 画像からの都市域分類を行い、さらに ASTER 画像分類結果、加工済み既存都市域データをオーバーレイしてから、確率テーブル作成部で作成された確率テーブルを用いて各画素が都市である条件付確率を計算する。最後に条件付確率の閾値を設定し、都市域を抽出する。

本研究では、手法中の各コンポーネントにおける手法の検討あるいはパラメータの検討を行った。始めに、既存データの buffering および thinning におけるバッファ距離を検討した。ここでは、既存のデータにバッファをかけた状態でバッファ距離別に精度検証を行い、精度の変化を元にバッファ距離を設定した。

続いて、ASTER 画像分類を行った。本研究では異なる 3 つの ASTER 画像分類方法を提案し、テストエリアにおける精度検証を行った。ここでは、各手法による分類結果の精度検証を行い、最も分類に適した手法を採用することとした。

続いて、ベイジアンネットワークを用いて条件付確率を推定し、確率テーブルを作成した。例えば、気候帯について考慮する場合、気候帯毎に条件付確率を推定することができるため、本過程においてデータを組合せることとした。

最後に、確率テーブルを用いてオーバーレイ画像の各画素が都市域である条件付確率を計算し、閾値処理によりテストエリアの都市域分類を行う。

全球処理を行う場合、実際に稼動するのは「データ処理部」である。今後全球展開にあたって、本研究で利用した 100 都市のテストエリアのデータから作成した都市域確率テーブルを、教師データとしてデータ処理部におけるインプットデータとして利用する。



### Ⅲ-2 目視判読による検証データの作成

ここでは、検証データの取得方法および作成手順について説明する。

#### i) 検証データの取得方法

検証データの取得方法としては、①画像中から各カテゴリに対応する検証データを作成する方法と②地図など画像以外の情報を利用して検証データを作成する方法がある。

本研究では、手法の自動化を目標としているため、②の方法によりグローバルに整備された画像以外の情報から検証データを取得するのが望ましいが、検証データとして利用可能な、位置精度の高い都市域データが存在しないため、本手法においては先にテストエリア 100 都市の目視判読結果を作成し、このうち半数をトレーニングデータとして、残りの半数を検証データとして利用する。つまり、本研究ではこの ASTER 画像の目視判読が唯一の手を介して行う作業となっている。

#### ii) 目視判読データの作成手順

今回は、対象 100 都市の ASTER 画像について各々約 500 箇所のポイントを発生させた。目視判読は経験などによる個人差があるため、ある程度の衛星画像を利用している人間であれば誰でも同じ結果が得られるよう、1 シーンあたり 3 名が目視判読を行い、多数決方式により、各ポイントのカテゴリを決定する。同一画像の判読結果の合致率は 87.996 ~ 92.687% であった。

1. ASTER 画像上にランダムに約 500 箇所のポイントを発生させる。
2. 各ポイントが都市であるか否かを目視によって判読する。都市および非都市の判定基準は、人工的土地被覆の有無とする。人工的な土地被覆や、建物が密集している地域を「都市」、森林や水域・田畑など人工物で覆われていない地域を「非都市」として判定する。
3. 目視判読結果には個人差が現れるため、1 枚あたり 3 名が同様の作業を行う。
4. 3 名の目視判読結果を元に、各ポイントについて多数決方式で都市・非都市の判定を行いこれを検証データとした。

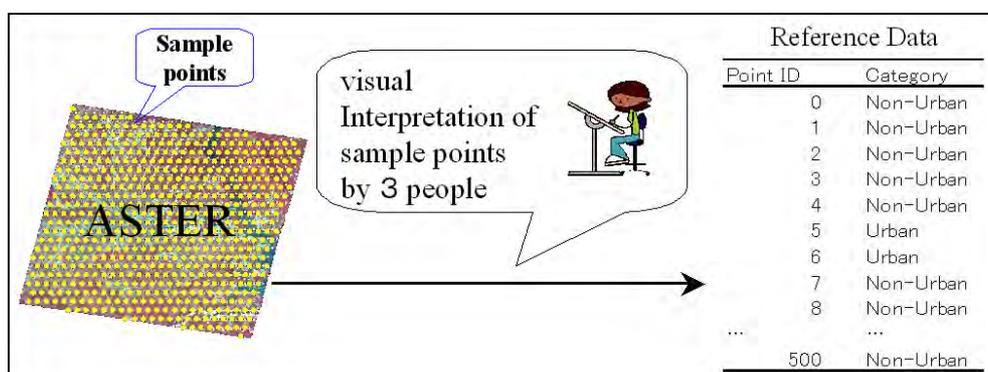


図 3.2 目視判読による検証データの作成

### Ⅲ－３ データ処理過程の検討

ここからは、各処理過程におけるパラメータ、処理手法について検討する。

#### Ⅲ－３．１ 既存データの加工

GRUMP/urban extent および MOD12/urban and built-up の都市域データに対して、buffering および thinning を行う。

##### i) GRUMP および MOD12 の加工条件

本研究で用いる既存データは、ともに分解能が約 1km と粗く、境界が細かく定義されていないため、都市と定義されているエリアにも都市以外の土地被覆を持つエリアが含まれている可能性があり、非都市とされているエリアにも人工的な土地被覆を持つ都市域が含まれている可能性があり、どちらも検出できるような形に加工することが望ましい。

GRUMP/urban extent では、都市域が実際よりも広く定義されているという特徴があった。このため都市域と定義されている領域の内側の領域ほど都市域である可能性が高いと考えられる。このため、thinning を行うことにより、都市域である可能性の高い地域を絞り込むことが期待できる。

MOD12/urban and built-up は、既存の土地被覆図の中でも比較的精度よく都市域が定義されているが、分解能が 1km であり、細かい都市の境界を拾うことができないという問題点があった。つまり、MOD12 の都市域境界付近では都市域境界の外側であっても都市域が存在する可能性が考えられ、また都市域境界の内側にも非都市域が混在していると考えられるため、thinning および buffering を行うことにより、都市境界を域である可能性が高い地域を絞りこむとともに、MOD12 では都市とされていない都市域の周辺部を拾い出すことが期待される。

##### ii) GRUMP および MOD12 に対するバッファ距離の決定

Buffering および thinning の距離を決定するために GRUMP および MOD12 の精度検証を行う。ここでは、目視判読結果を利用してバッファ距離毎に精度検証を行った。精度検証については、User's Accuracy, Producer's Accuracy, Overall Accuracy および Kappa 係数の算出により精度検証を行うこととした。

### III-3.2 ASTER 画像分類

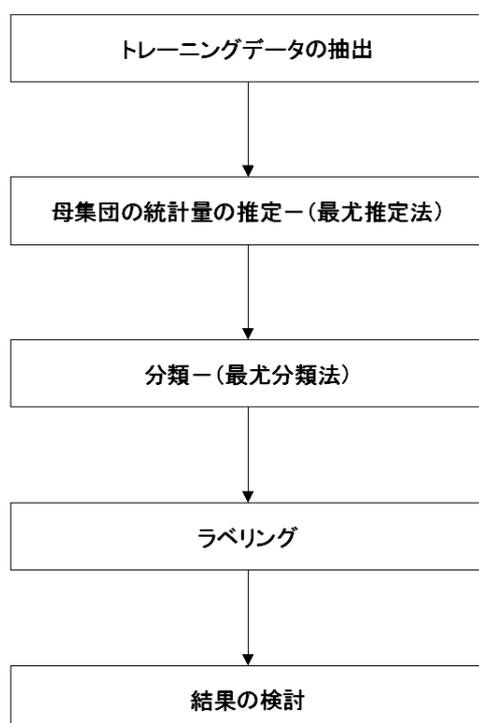


図 3.3 ASTER 画像教師なし分類処理

#### i) 衛星画像の分類手法と手法の自動化

衛星画像分類の処理過程は、図 3.3 のように「トレーニングデータの抽出」、「母集団の統計量の推定」、「分類」、「ラベリング」、「精度検証」という手順を踏むのが一般的である。分類手法はトレーニングデータの取得方法により教師つき分類と教師なし分類の 2 つに大別される。

教師つき分類は、あらかじめ定められたカテゴリを最もよく代表していると思われる領域を抽出したラベルつきトレーニングデータを利用するのに対し、教師なし分類は、画像中からランダムに選んだ画素を、特徴空間においてクラスタリングしたものをトレーニングデータとして利用する(図 3.4)。つまり、教師つき分類ではトレーニングデータとカテゴリが対応しているのに対し、教師なし分類では、図 3.4 のように自動的にラベルの貼られていないトレーニングデータが作成されるため、

画像中にどのようなカテゴリが存在するのかわからない場合に用いられることが多い。

本研究では処理過程の自動化を目標としているため、トレーニングデータをランダムに取得する教師なし分類手法を用いることとする。教師なし分類では、トレーニングデータにラベルが貼られていない。このため、ASTER 画像の教師なし分類の自動化を行う上で一番問題となるのがラベリングの自動化である。

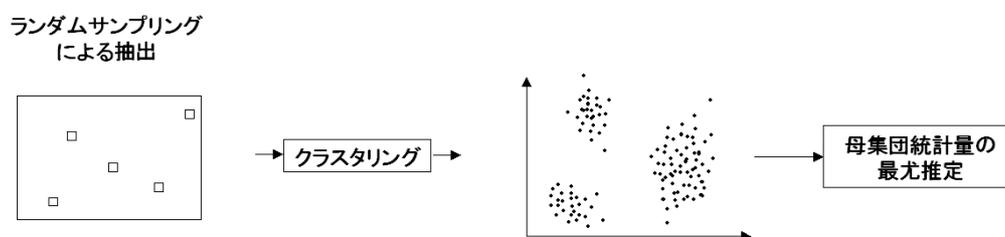


図 3.4 クラスタリングによるトレーニングデータの取得

iii) ラベリング方法

衛星画像の教師なし分類にあたって問題となるのが、いかにしてラベリングを自動化するかである。ラベリングの代表的な方法は、以下の3つの方法が挙げられる。

1. 再分類する方法：クラス間距離による方法

分類結果の各クラスの RGB 値の平均を出す。各カテゴリの領域を設定し、各カテゴリにおける各クラスの RGB 値の平均を計算する。各クラスを対象要素とした RGB 空間上の点の距離を計算し、最も距離の近いクラスの属すカテゴリと同じカテゴリに各クラスを再分類し、ラベリングを行う。

2. 多数決で自動決定する方法

始めに、各カテゴリを示す領域を設定する。

次に、各カテゴリ  $\omega_j$  の領域内でクラス  $c_i(i=1,2,\dots,N_c)$  が占める面積  $A_{ij}$ (画素数) を求め、カテゴリ  $\omega_j$  の画素数で除し、各クラスのカテゴリ内面積シェアを計算する。面積シェアが閾値以上のとき、 $c_i$  をカテゴリ  $\omega_j$  に対応づける。

あるいは、各クラスごとに表 3.1 を 1 行ずつ見ていき、カテゴリ  $\omega_j(j=1,2,\dots,N_\omega)$  の中で最大面積のカテゴリにそのクラス  $c_i$  を対応づける。

表 3.1 クラスのカテゴリ別占有面積表

クラス	カテゴリー			
	$\omega_1$	$\omega_2$	...	$\omega_{N_\omega}$
$c_1$	$A_{11}$	$A_{12}$	...	$A_{1N_\omega}$
$c_2$	$A_{21}$	$A_{22}$	...	$A_{2N_\omega}$
...	...	...	...	...
$c_{N_c}$	$A_{N_c1}$	$A_{N_c2}$	...	$A_{N_cN_\omega}$

3. 再分類する方法

まず、各カテゴリを示す領域を設定する。この領域は、再分類のための訓練エリアとして扱われる。

カテゴリは複数のクラスから構成されていると考え、カテゴリ  $\omega_j$  ごとに訓練エリア内の各クラス  $c_i$  の構成比  $h_j(c_i)$  を次式のように求め、それを訓練データとする。

$$h_j = [h_j(c_1)h_j(c_2) \cdots h_j(c_{N_c})]$$

$$= [n_1/N_j \cdot n_2/N_j \cdots n_{N_c}/N_j]$$

ただし、

$n_i$  : 訓練エリア内のクラス  $C_i$  の出現頻度

$N_j$  : カテゴリ  $\omega_j$  の訓練エリアの画素数

次に、1次分類結果画像で、局所領域ごとに各クラスの構成比  $h(c_i)$  を次式のように求める。

$$h=[h(c_1)h(c_2) \cdots h(c_{Nc})]$$
$$=[m_1/W \cdot m_2/W \cdots m_{Nc}/W]$$

ただし、

$m_i$  : 局所領域内の  $C_i$  の出現頻度

$W$  : 局所領域の画素数

局所領域としては  $5 \times 5$  画素程度のウィンドウが使用され、もっとも類似した構成比を示すカテゴリをそのウィンドウの中心画素に割り当てる。この判定はヒストグラムマッチング法(\*)を使って行われる。

#### iv) ASTER 画像分類手法

3. に示した再分類方法を用いた場合、データ処理が複雑化し、データ処理時間が長くなることから、ここでは1, 2のラベリング方法を用いて ASTER 画像を分類する。(手法2に関しては最大値と面積シェアの両手法について検討する。)

ラベリング方法の異なる以下の手法①, ②, ③を用いて分類を行い、分類結果について精度を検証し、最も精度のよい手法を採用することとする。

手法① : RGB 空間上のクラス間距離を元にラベリングを行う方法

はじめに、ASTER 画像の教師なし分類を行い、10のクラスに分類する。

次に、GRUMP および MOD12 のどちらにおいても都市と定義されているエリアにマスクをかけた ASTER 画像を教師なし分類により5クラスに分類する。

同様に、GRUMP および MOD12 のどちらにおいても非都市と定義されているエリアにマスクをかけた ASTER 画像を7クラスに分類する。

それぞれのクラスタリング結果のRGB値の平均をとり、各クラスのRGB空間上の点を定義する。

始めに分類された10クラスについて、都市および非都市のクラスから、RGB空間上で最も近いポイントを計算し、最も近いクラスが都市であった場合そのクラスを都市、最も近いクラスが非都市であった場合非都市のラベルを貼る。

手法②：面積シェアの高いものをラベリング(閾値)

はじめに，ASTER 画像の教師なし分類を行い，10 のクラスに分類する。

次に，各画像における画像全体に占める MOD12 で都市と定義された面積の割合を算出する。

続いて，各クラスと MOD12 を重ね合わせ，各クラスの全体の面積に占める，各クラスのうち MOD12 で都市と定義されたエリアと重なっている部分の面積シェアを各クラスについて算出する。

各クラス的面積シェアが，MOD12 における都市域の面積シェアと比較して 150%よりも大きい場合を都市，それ以外を非都市としてラベルを貼る。

手法③：面積シェアの最も高いクラスを都市としてラベリング

はじめに，ASTER 画像の教師なし分類を行い，10 のクラスに分類する。

次に，各画像における画像全体に占める MOD12 で都市と定義された面積の割合を算出する。

続いて，各クラスと MOD12 を重ね合わせ，各クラスの全体の面積に占める，各クラスのうち MOD12 で都市と定義されたエリアと重なっている部分の面積シェアを各クラスについて算出する。

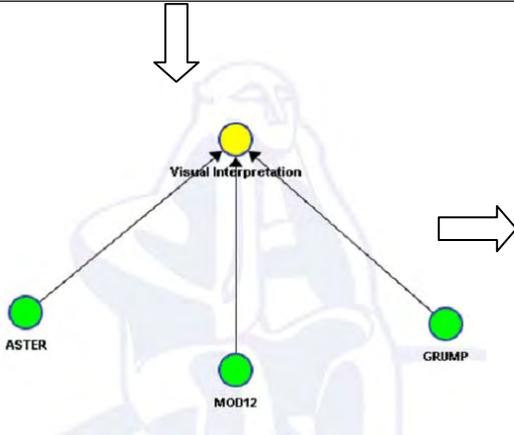
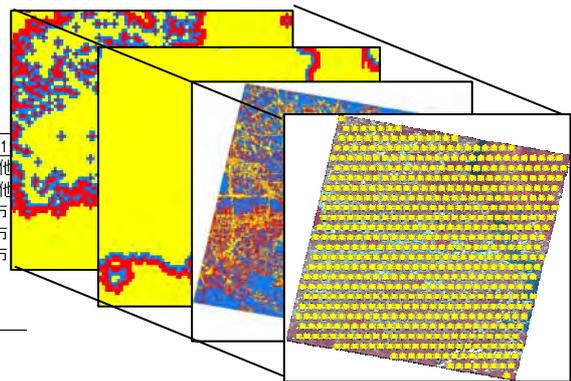
面積シェアが最も大きい場合を都市，それ以外を非都市としてラベルを貼る。

### Ⅲ-3.3 ベイジアンネットワークモデルを用いた条件付確率の計算

ベイジアンネットワーク(Bayesian network, Bayesnet, belief network)とは複数の確率変数の間の定性的な依存関係をグラフ構造によって表し、個々の変数の間の定量的な関係を条件付確率で表した確率モデルである。確率変数と、その間の依存関係を表すグラフ構造、条件付確率、の集合によって定義される。ここでは、条件付確率の推定ができるベイズ推定ソフトの BayesiaLab を用いて条件付確率の推定を行った。図 3.5 のような簡単なベイジアンネットワークモデルを利用して、確率テーブルを作成した(図 3.6)。

この確率テーブルは、オーバーレイ画像においてどののエリアにマスクをかけるかを決定するのに用いられる。

point	x	y	目視判読結果	ASTER	GRUMP	MOD1
1	74.78581478	28.22864433	その他	その他	その他	その他
2	74.81220081	28.22864433	その他	その他	都市	その他
3	74.83858684	28.22864433	その他	その他	都市	都市
4	74.86497287	28.22864433	都市	その他	都市	都市
5	74.89135889	28.22864433	都市	都市	都市	都市
⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮



ASTER	GRUMP	MOD12	A-②	B-②	C-②	D-②	E-②
	Urban	Urban	100	100	92.04	69.57	100
		Thin	52.63	66.87	75.83	51.85	100
		Buffer	45.45	16.67	53.97	28.57	22.5
	Non-Urban	Urban	40	0	57.58	5.88	0
		Thin	100	50	71.43	75	100
		Thin1	66.67	16.67	72.22	77.78	50
Urban	Thin1	Buffer	75	0	33.33	50	50
		Non-Urban	16.67	0	27.27	20	0
		Urban	100	50	100	50	100
Urban	Thin2	Thin	70.37	50	52.86	66.67	50
		Buffer	70	37.5	21.05	26.32	50
		Non-Urban	30	6.45	9.15	10.71	0
Non-Urban	Thin2	Urban	50	50	92.04	50	50
		Thin	100	0	75.83	0	50
		Buffer	25	0	53.97	10	0
		Non-Urban	4.88	1.2	57.58	2.39	0

図 3.5 ベイジアンネットワークモデル

図 3.6 確率テーブル

### Ⅲ－３．４ 都市域マッピング

ここでは図 3.1 の「データ処理部」にある一連のデータ処理を用いて、実際に都市域をマッピングした。「確率テーブル作成部」において計算された条件付確率テーブルを利用して、オーバーレイ画像の各ピクセルがそれぞれ何%の確率で都市であるかを計算し、閾値処理により、都市域のマッピングを行う。作成された都市域マップから、本手法による分類の特徴について考察し、本手法による都市域分類精度を検証する。

### Ⅲ－４ 精度検証方法

精度評価： 都市域分類結果を目視判読により作成した検証データと比較する。

Producer's accuracy： 目視判読により作成された検証データの何%が分類結果と一致したか

User's accuracy： 分類結果のうち何%が正しく分類されたか

Overall Classification accuracy： 総合分類精度

Kappa 係数： 無作為な割り当てをどれだけ回避しているかを示す

分類精度評価には、Error matrix 表を用いる(表 3.2)。対角成分の合計をサンプルの総数で除したものが、Overall accuracy である。このほかに、行列の縦方向と横方向で、精度を出す方法があり、表 3.2 の縦方向で算出する精度が Producer's Accuracy、横方向で算出する精度が User's Accuracy と呼ばれている。Producers Accuracy は目視判読により作成されたデータのうち何%が分類結果と一致したかを表している。また、User's Accuracy は、分類結果の各画像における各クラスの何%が正しく分類されたか、という信頼度を表現したものである。この Error Matrix 表による分類精度の表現方法として、User's accuracy のほかに Kappa 係数がある。Kappa 係数の算出にも、Error Matrix 表が用いられる。Kappa 係数は、無作為な割り当てをどれだけ回避しているかを示すものであり、Overall accuracy と同様に値が高いほど高精度であることを意味するが、全体精度とは異なり、列の総和、行の総和を考慮しているため、一般的にはより包括的な表現が可能な係数であるといわれている。

しかしながら，本研究では，分類カテゴリは「都市域」と「その他」の2つしか存在しない．また，テストエリアの都市においては画像中における都市域が極端に小さいものも多く，都市域分類精度の指標として Overall accuracy や Kappa 係数では好ましくない場合がある．そこで，本研究における分類精度検証では主に都市カテゴリの Users Accuracy を利用する．

表 3.2 Error Matrix

		検証データ		
		都市域	その他	計
分類結果	都市域	$C_{11}$	$C_{12}$	$C_{13}$
	その他	$C_{21}$	$C_{22}$	$C_{23}$
	計	$C_{31}$	$C_{32}$	$C_{33}$

$$\text{User's accuracy} = \frac{\text{正しく都市と分類されたサンプル数 } (C_{11})}{\text{分類結果において都市とされたサンプル数 } (C_{13})} \times 100$$

$$\text{Producer's accuracy} = \frac{\text{正しく都市と分類されたサンプル数 } (C_{11})}{\text{目視判読において都市とされたサンプル数 } (C_{31})} \times 100$$

$$\text{Overall accuracy} = \frac{\text{正しく分類されたサンプル数 } (C_{11} + C_{22})}{\text{合計サンプル数 } (C_{33})} \times 100$$

## 第IV章 検証

#### IV-1 既存データの加工

ここでは、GRUMP の thinning、MOD12 の buffering および thinning 距離を検証する。

##### i) バッファ距離の検証手順

GRUMP に対し、1km 間隔毎に 10km の距離まで thinning および buffering を行う。同様に MOD12 に対し、1km 間隔毎に 10km の距離まで thinning および buffering を行う。

各バッファ境界線を都市域境界と仮定し、各距離における都市域分類精度を計算する。

##### ii) 結果

GRUMP および MOD12 の精度と、buffering および thinning を行ったときの精度を、図 1、2 のグラフに表した。

GRUMP の精度は、都市域の User's accuracy が約 30%となっており、GRUMP の精度の低さを裏付ける結果となった。しかしながら、Producer's accuracy は約 90%と高くなっている。これは、GRUMP の特徴のひとつであった面積の過大評価を裏付ける結果となった。

thinning 距離は-2km および-5km とした。thinning 距離が長くなるほどバッファ内部が都市域である確率(User's accuracy)は高くなるが、抽出したい都市が、半径 10km を超えるサイズのものばかりであるとは限らないため、User's accuracy が 50%を超える-5km 地点での thinning を行うこととする。また、GRUMP は面積が課題評価されているため thinning 距離を長くてもしくはばらくは Producer's accuracy の高い状態が続く。そこで、Producer's accuracy が 85%を切る-2km 地点ごろからバッファ内の非都市域面積が増加し始めると考え、-2km の距離で thinning を行うこととする。

MOD12 の精度は、都市域の User's accuracy が約 60%程度であった。これは岩男らによる精度検証結果と同程度の精度であった。Producer's accuracy も約 75%であり、GRUMP と比較して精度よく都市域が定義されていることが分かった。

MOD12 に関しては、-2km 地点で thinning を、1km 地点で buffering を行うこととした。thinning 距離が長くなるほどバッファ内部が都市域である確率(User's accuracy)は高くなる。そこでバッファ内部の領域が高い確率で都市であるといえる領域を設定するため、User's accuracy が 80%を超える-2km 地点での thinning を行うこととする。また、1km 地点から Producer's accuracy が 80%を超えるため、80%以上の都市域がバッファの領域内に納まっている状態となるため、1km 地点で buffering を行うこととした。

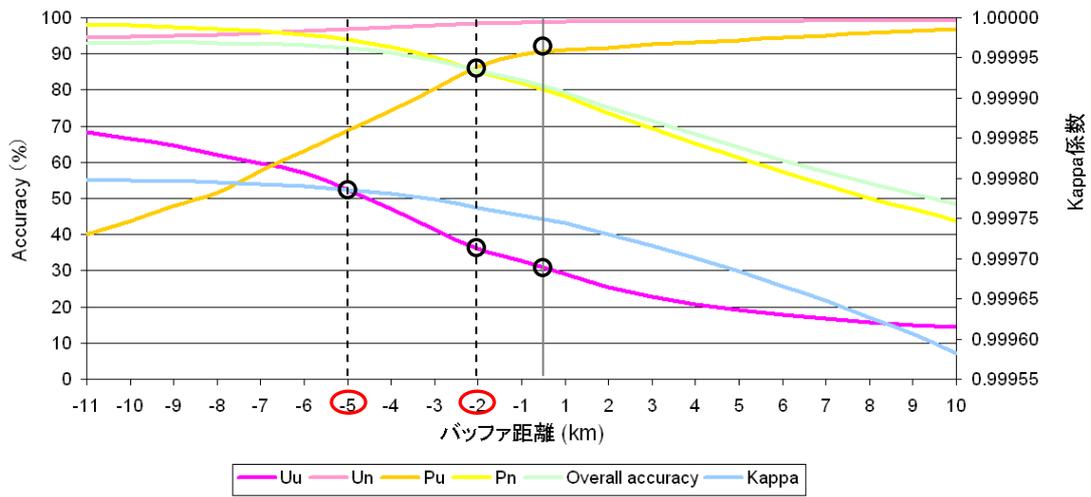


図 4.3 GRUMP 精度

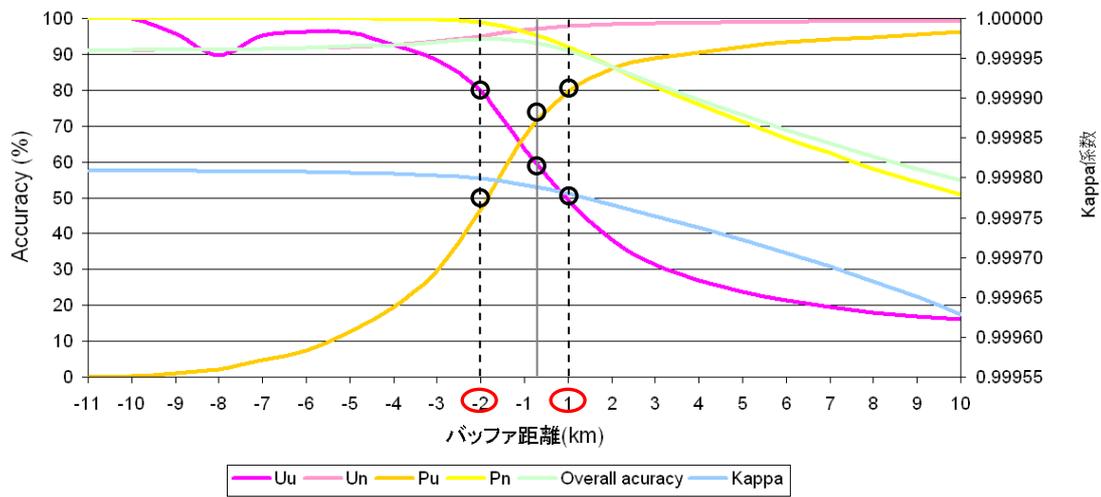


図 4.4 MOD12 精度

## IV-2 ASTER 画像分類

ここではラベリング方法の異なる3パターンのASTER画像分類手法の精度を比較する。

### i) 精度検証

Ⅲ章の3.2節で提案した手法①～③を用いてASTER画像の画像分類を行った。画像分類結果について、Error Matrix表およびKappa係数を用いて精度検証を行う。各手法による画像分類結果の精度を比較し、どの手法が最も精度よく都市域を分類できるかを検討する。

### ii) 結果

1 手法①～③を用いた103都市のASTER画像分類の分類精度を、図4.3に示した。

手法①による分類では、全体的に精度が低く、103都市の内86都市における分類精度が10%以下であり、最大でも28.10%の都市域を抽出する程度であった。手法②は、①～③の中で最も精度よくASTER画像を分類することができた。103シーン中91シーンで他の手法よりも精度よく都市域を分類している。手法③を用いた場合の分類制度を見ると、手法①と比較するとおおむね精度よく分類されているが、手法②と比較して精度よく分類された画像は6シーンのみであり、その他のシーンでは②よりも低い精度となった。

次に、手法①～③でASTER画像分類の分類精度と、GRUMP/urban extentおよびMOD12/urban and built-upの精度とを比較した。GRUMP/urban extentの精度と比較したときの都市抽出精度の改善率を図4.4に、MOD12/urban and built-upの精度と比較したときの都市抽出精度の改善率を、図4.5に示した。また、各手法について、GRUMP/urban extentおよびMOD12/urban and built-upと比較した場合の改善ケース数を表4.1に示し、改善率別のケース数を図4.6にグラフ化した。

手法①では、GRUMPと比較した場合69シーンにおいて、MOD12と比較した場合94シーンにおいて改善率がマイナスの値を示している。手法①による都市域マッピングでは既存の都市域データよりも精度のよい都市域マップを作成することは困難であることが分かった。

表 4.1 改善ケース数

	GRUMP/urban extent			MOD12/urban and built-up		
	手法①	手法②	手法③	手法①	手法②	手法③
worsen	69	9	26	94	16	78
improved	34	94	77	9	87	25

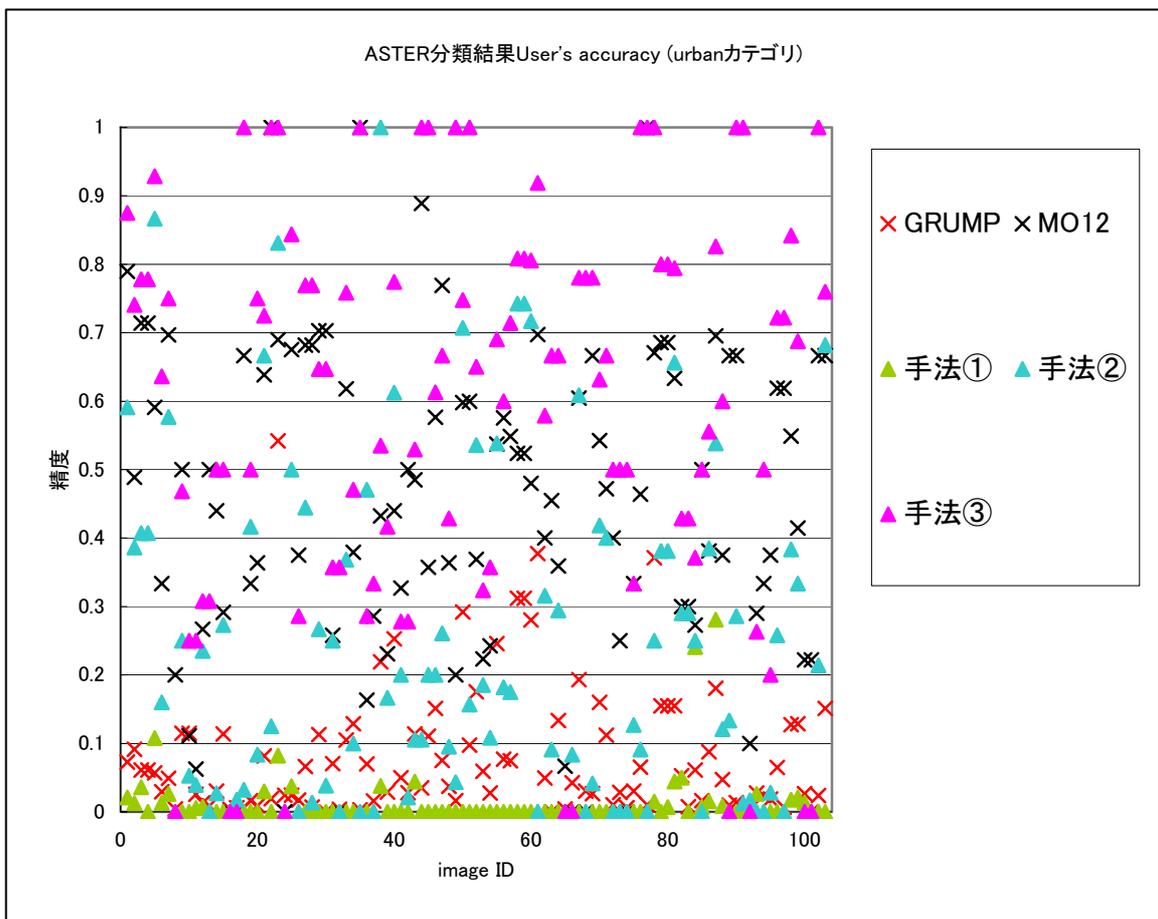


図 4.5 ASTER 画像分類結果の各画像の精度

手法②の精度について、GRUMP と比較した場合 94 シーンにおいて、MOD12 と比較した場合 87 シーンにおいて改善率がプラスの値を示した。手法②による都市域マッピングは既存の都市域データと比較して多くの地域で精度の向上がみられる可能性が高い。しかし、GRUMP と比較した場合、9 シーンにおいて、MOD12 と比較した場合 16 シーンにおいて改善率がマイナスの値を示している。

手法③の精度について、GRUMP と比較した場合、77 シーンにおいて改善率がプラスの値を示しているが、MOD12 と比較した場合 78 シーンにおいて改善率がマイナスの値を示しており、既存の都市域データと比較して精度よく都市域マップを作成することが困難であると考えられる。しかし、手法②と比較したとき 6 シーンにおいては手法②よりも高い改善率が見られた。

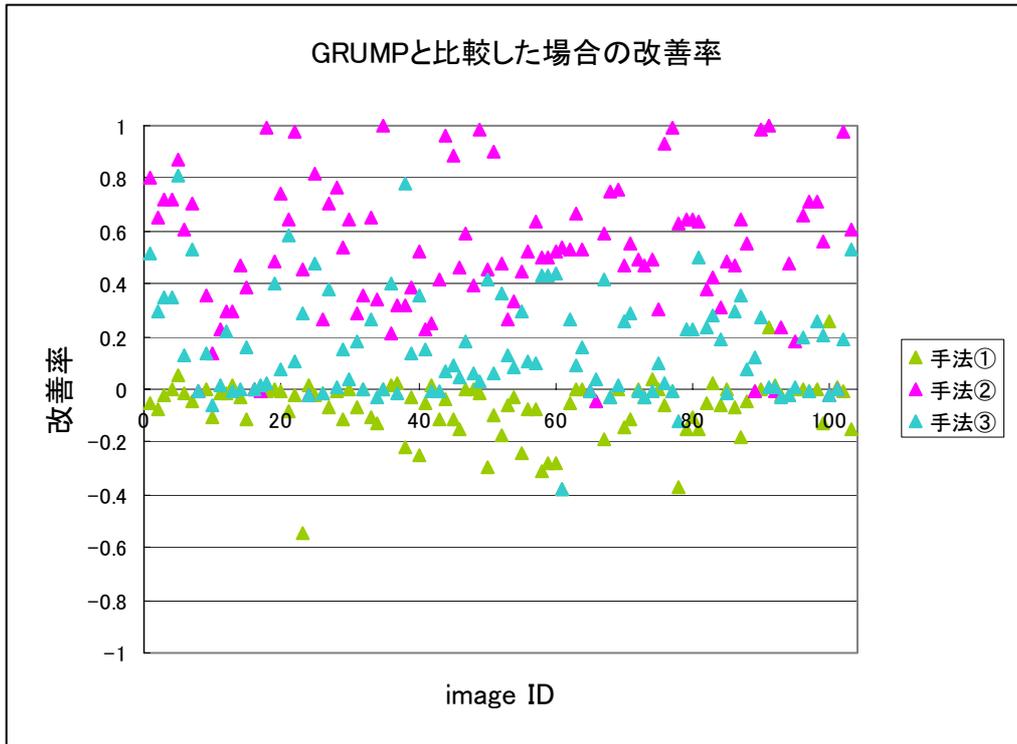


図 7.4 ASTER 画像分類結果と GRUMP 精度の比較

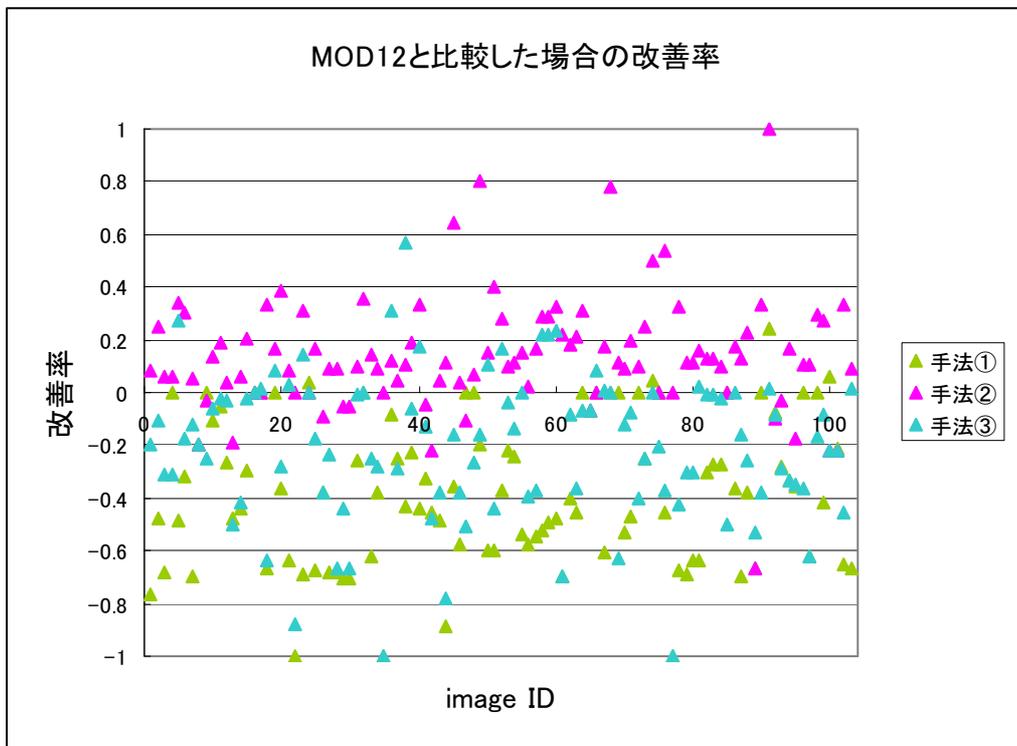


図 6.5 ASTER 画像分類結果と MOD12 精度の比較

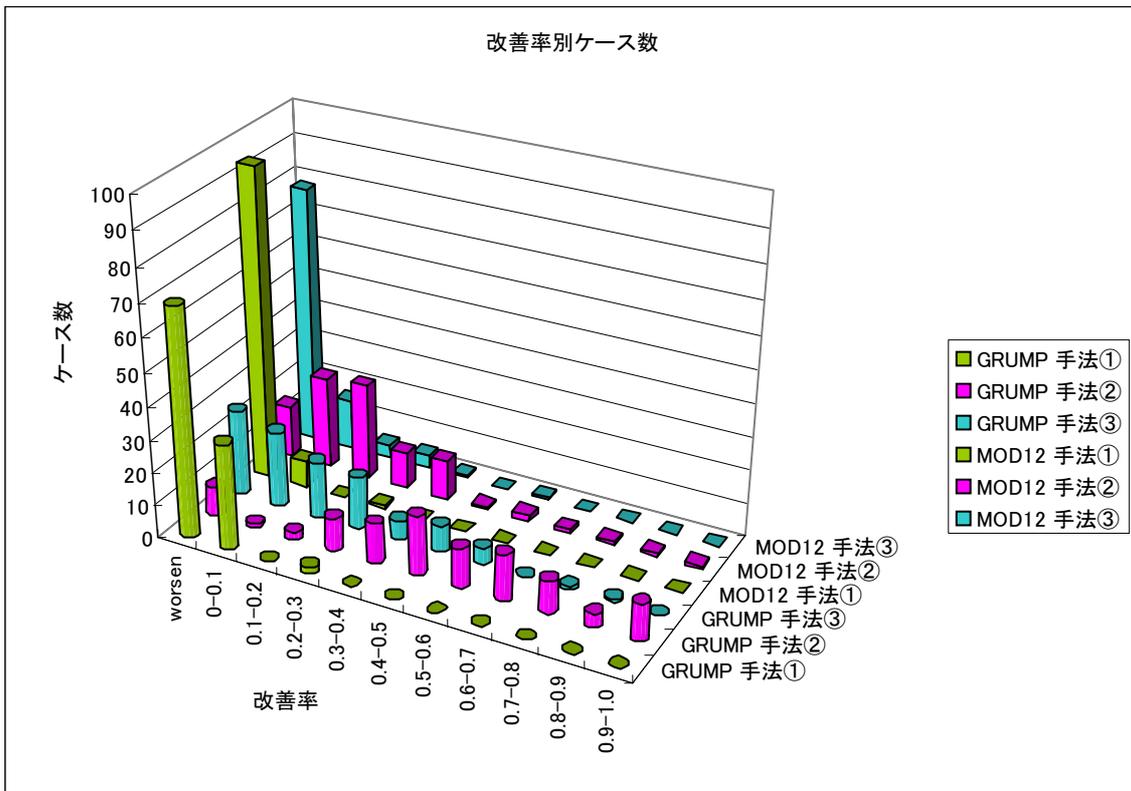


図 4.6 改善率別ケース数

### IV-3 ベイジアンネットワークモデルを用いた条件付確率の推定

#### i) 条件付確率テーブルの作成と確率テーブルに関する分析

ベイジアンネットワークモデルを用いて事後確率の推定を行い、確率テーブルを作成した(表 4.2, 4.3)。ここでは、気候帯毎に条件付確率を推定した。この確率テーブルから図 4.7を作成した。この図は手法②, ③における気候帯ごとの条件付確率をプロットしたものである。X軸はMOD12の都市境界からの距離ごとに並べられている。条件付確率を並べ替えたところ、グラフの傾きが右下がりになる傾向があることがわかった。都市のコアに近づくほど条件付確率が高く、都市域から離れるほど条件付確率が低くなるという傾向が伺える。これはすなわち、都市域マッピングにおいて MOD12 の信頼度が高いということを意味している。

参考までに x 軸を GRUMP の都市境界線からの距離に並べ替えたものを図 4.8 に示した。ジグザクとした波形のような形を示しており、GRUMP の信頼度が MOD12 ほど高くないということを示した。

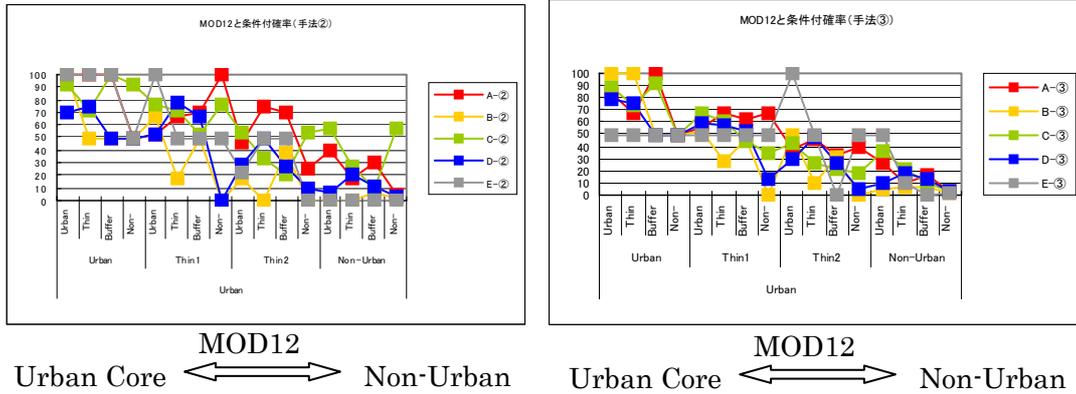
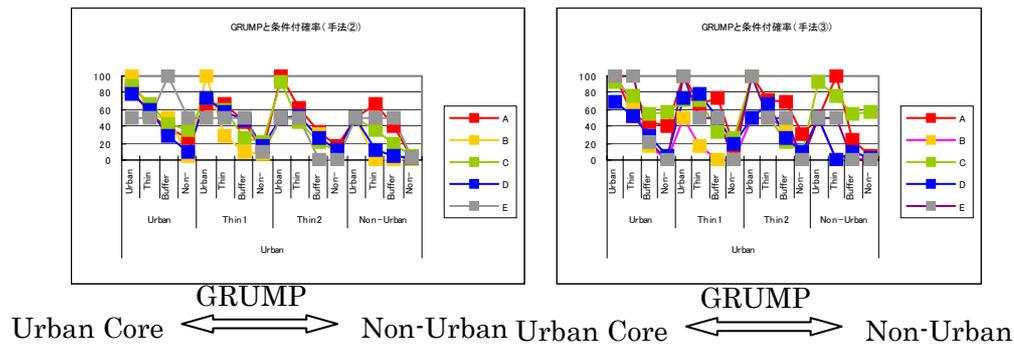


図 4.7 手法②, ③における条件付確率



[参考] 図 4.8 手法②, ③における条件付確率

表 4.2 確率テーブル (手法②)

手法②	ASTER	GRUMP	MOD12	Koeppen Climatic Zone				
				A	B	C	D	E
Urban	Urban	Urban	Urban	83.33	10	87.8	78.43	50
		Thin	55.77	52.38	67.63	59.09	50	
		Buffer	38.1	50	42.34	28.81	100	
	Thin1	Urban	Urban	26.67	4.76	35.63	9.46	50
		Thin	66.67	100	73.91	75	50	
		Buffer	66.67	28.57	58.88	58.08	50	
	Thin2	Urban	Urban	46.15	9.09	25.88	47.83	50
		Thin	10	6.25	20.98	17.78	10	
		Buffer	100	50	92.31	50	50	
	Non-Urban	Urban	Urban	63.04	46.67	44.56	51.72	50
		Thin	33.33	30.77	21.71	25.58	0	
		Buffer	16.44	7.23	9.22	12.95	0	
Non-Urban	Urban	Urban	50	50	50	50	50	
	Thin	66.67	0	34.92	12.5	50		
	Buffer	40	0	17.98	5.28	50		
Non-Urban	Non-Urban	Non-Urban	3.57	1	3.77	2.93	1.99	

表 4.3 確率テーブル (手法③)

手法③	ASTER	GRUMP	MOD12	Koeppen Climatic Zone				
				A	B	C	D	E
Urban	Urban	Urban	Urban	100	100	92.04	69.57	100
		Thin	52.63	66.67	75.83	51.85	100	
		Buffer	45.45	16.67	53.97	23.57	22.5	
	Thin1	Urban	Urban	40	0	57.58	5.88	0
		Thin	100	50	71.43	75	100	
		Buffer	66.67	16.67	72.22	77.78	50	
	Thin2	Urban	Urban	75	0	33.33	50	50
		Thin	16.67	0	27.27	20	0	
		Buffer	100	50	100	50	100	
	Non-Urban	Urban	Urban	70.37	50	52.98	68.67	50
		Thin	30	37.5	21.05	28.32	50	
		Buffer	30	6.45	9.15	10.71	0	
Non-Urban	Urban	Urban	50	50	92.04	50	50	
	Thin	100	0	75.83	0	50		
	Buffer	25	0	53.97	10	0		
Non-Urban	Non-Urban	Non-Urban	4.88	1.2	57.58	2.39	0	

#### IV-4 都市域マッピング

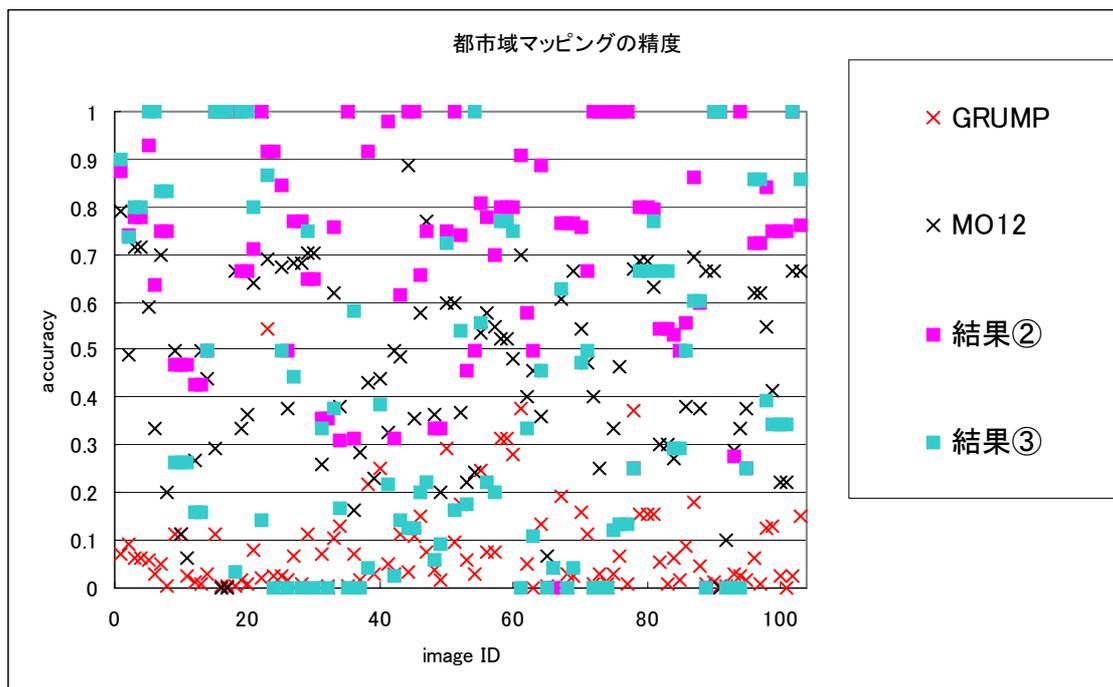


図 4.9 都市域マッピングの精度

最後に、テストエリア 103 都市における全てのシーンについて、本研究で提案した都市域マッピング手法による都市域分類(図 3.1 データ処理部における処理)を行った。IV-2 において、手法①～③で ASTER 画像を分類した時の精度検証を行った。その際、手法①による ASTER 画像分類結果は極端に精度が低かった。このためここでは、手法②および③を用いた都市域マッピングを行い、マッピングの精度を、図 4.9 に示した。

手法②から得られた結果は、手法③よりも分類精度が高い。手法③で得られた結果は、②よりも低い精度となった。

次に、手法①～③で ASTER 画像分類の分類精度と、GRUMP/urban extent および MOD12/urban and built-up の精度とを比較した。GRUMP/urban extent の精度と比較したときの都市抽出精度の改善率を図 4.4 に、MOD12/urban and built-up の精度と比較したときの都市抽出精度の改善率を、図 4.5 に示した。また、各手法について、GRUMP/urban extent および MOD12/urban and built-up と比較した場合の改善ケース数を表 4.1 に示し、改善率別のケース数を図 4.6 にグラフ化した。

手法②では、GRUMP と比較した場合、98 シーンにおいて、MOD12 と比較した場合 89 シーンにおいて改善率がプラスの値を示しており、手法②による都市域マッピングでは既存の都市域データと比較してほとんどの地域で精度の高い都市域マップを作成できることが分

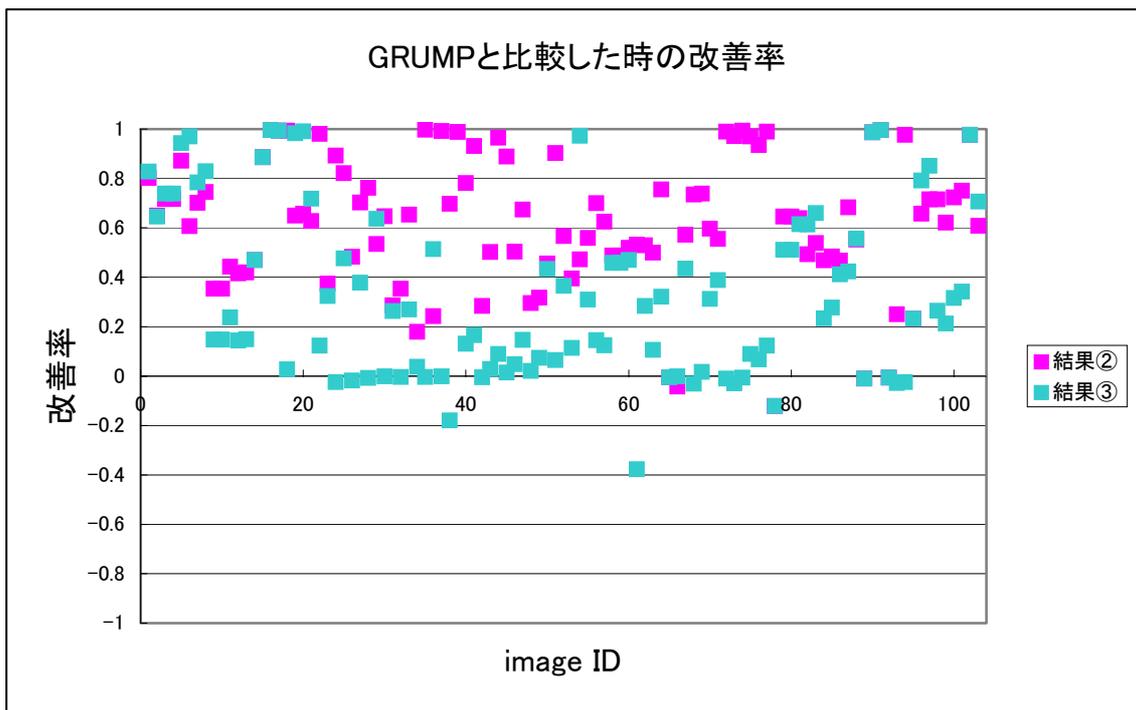


図 4.10 都市域マッピング結果と GRUMP 精度の比較

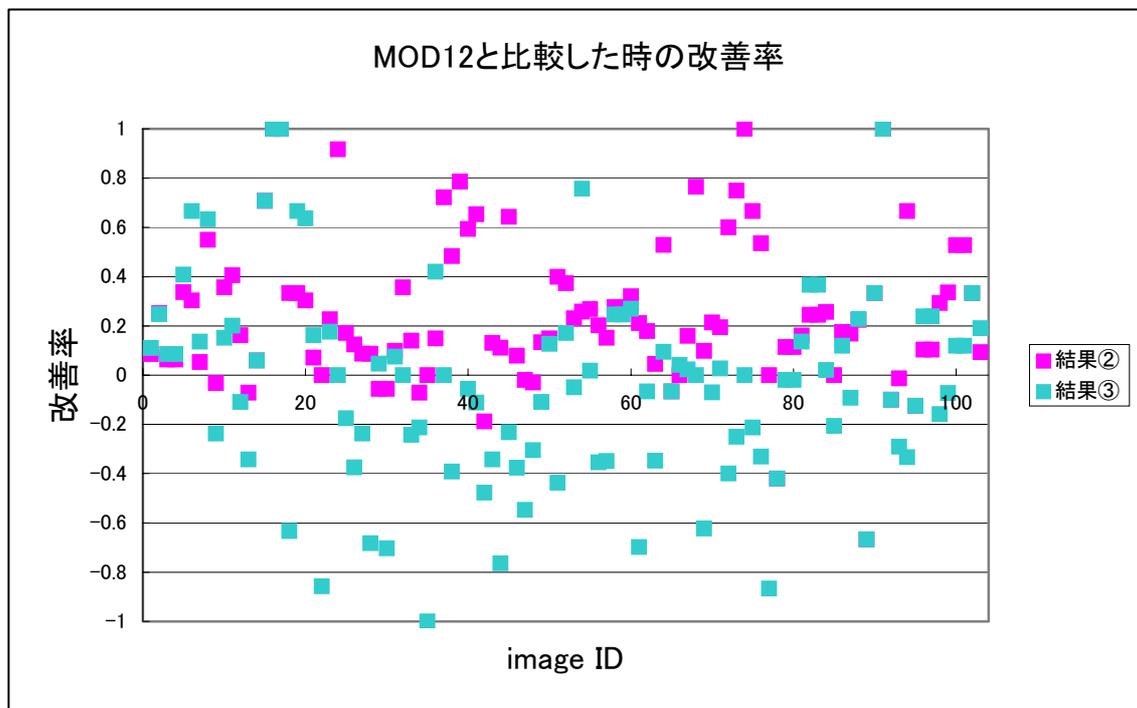


図 4.11 都市域マッピング結果と MOD12 の精度の比較

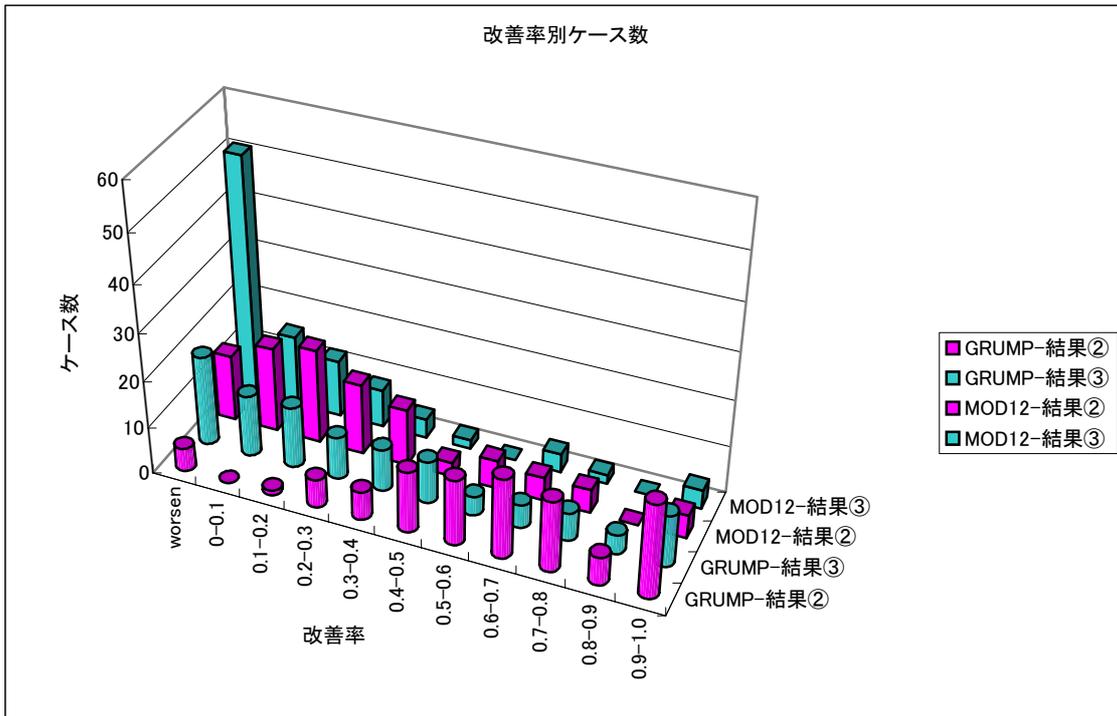


図 4.12 改善率別ケース数

かった。しかし、GRUMP と比較した場合、5 シーンにおいて、MOD12 と比較した場合 14 シーンにおいて改善率がマイナスの値を示している。

手法③では、GRUMP と比較した場合、83 シーンにおいて改善率がプラスの値を示しているが、MOD12 と比較した場合 51 シーンにおいて改善率がマイナスの値を示している。手法③を用いて都市域マッピングを行った場合、既存の都市域データと比較して同程度の精度しか得られないと考えられる。

#### IV—5 考察

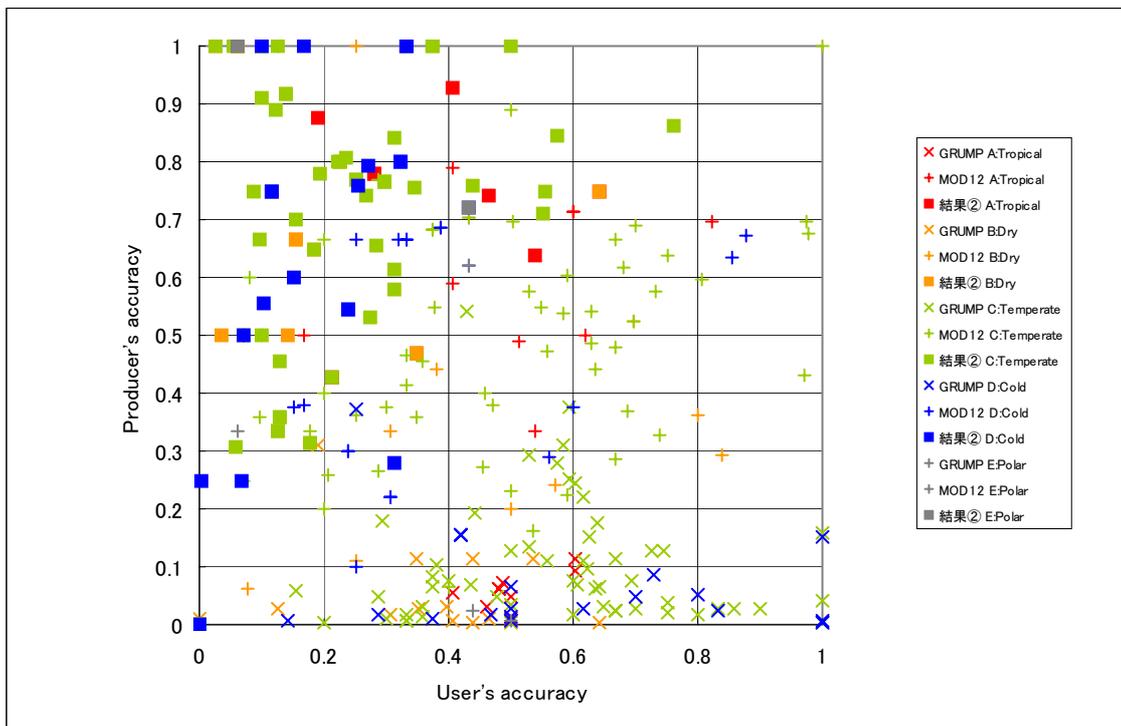


図 4.13 気候帯別精度検証

##### i) 都市域マッピングの精度検証

全画像の都市域マッピング結果を図 4.13 にプロットした。図 4.13 は x 軸に User's accuracy を、y 軸に Producer's accuracy を取っており、右上方ほど分類精度が高いことを現している。また、図中に記した  $x=y$  の直線よりも右下方に点がプロットされている場合は面積が過大評価されていることを表し、左上方に点がプロットされている場合は面積が過小評価されていることを表している。

図 4.13 より、本手法によりマッピングされた都市域は User's accuracy が高く、Producer's accuracy が低めになっている。全体的に、面積はやや過小評価されていることが分かった。

## ii) 本手法による都市域マッピングの問題点

実際に都市域マッピングを行ったところ、以下のような誤分類が見られた。

- ・ 雲の陰を都市域として分類する。
- ・ 水域を都市域として分類する。
- ・ 畑を都市域として分類する。
- ・ 都市域と非都市域が逆転する。
- ・ 都市域の一部しか抽出できない。
- ・ 山岳地帯などの小都市において都市域以外の地域も広く都市として分類する。

それぞれの誤分類について、代表的なシーンを表〇に示した。

雲の陰を都市域として分類してしまう誤分類があった。都市域に雲がかかっていたため、雲の陰まで都市域の教師データとなってしまうと考えられる。通常、ASTER データの取得段階において、雲量を指定することができること、ASTER 画像では雲量 0% のグローバルアーカイブが完成していることから、うまく画像を選択することができれば通常はこのようなことは起こりにくい。しかし、雲量 0% の画像を取得しても今回のようにところどころ雲が見られる画像は存在するため、今後は雲および雲の陰を除去するようなステップを自動化する必要がある。

また、分類結果のうち、水を都市として誤分類してしまうケースが見られた。普通水域では近赤外域をほとんど反射しないため、一般には衛星画像を用いた分類で水域を都市域と分類してしまうケースは少ない。しかし、十分な精度を持たない GRUMP および MOD12 をラベリング時の教師データとして利用したため、GRUMP、MOD12 の双方で都市域とされたエリアの内部に川や池・海などの比較的広い水域が存在した場合は水域に都市のラベルが張られてしまうと考えられる。水域の誤分類を除去するためには、分類システムに近赤外バンドを用いた閾値処理による水域除去過程を組み込むことが有効であると考えられる。

このほかに、都市域周辺に農地が広がっているような画像では、多くの場合田畑を都市として誤分類してしまうケースが見られた。耕作中の農地では植生が存在するため、都市として誤分類されることは少ないが、収穫後や休耕中の農地で地表面がむき出しになっているような場所が都市として誤分類されてしまうケースが見られた。ASTER 画像単独の分類のみでこういった季節変化による影響を取り除くのは困難である。なぜなら ASTER 画像は時系列データが十分に揃っておらず、都市域の抽出に最も適した季節の画像を入手できるとは限らないためである。こういった誤分類は、他のデータとの組合せを考える必要がある。

また、山岳地帯などの小都市において都市域以外の地域が広く都市域として分類されるなど、地形の影響と考えられる誤分類がみられた。この場合、DEM の組合せが有効であると考えられる。通常、都市は急傾斜地には発展しにくいいため、DEM を利用して急傾斜地に現れる都市域を省くことができると考えられる。

全体的な傾向として、手法①、②では非都市域のクラスまで拾ってしまう場合が多かった。これは、都市域分類でしばしば問題となるミクセル<sup>7</sup>が原因のひとつであると考えられる。また、GRUMP および MOD12 の精度が十分でないにも関わらず、ラベリングの教師としてこれらのデータを使ったことも原因のひとつである。例えば、GRUMP、MOD12 とともに分解能は 1km となっているが 1 画素(1km×1km)が「都市」と定義された場合、そのピクセルには都市的土地被覆と非都市的土地利用が混在していることが多い。

---

<sup>7</sup> ミクセル：一画素の中にさまざまな土地利用が混ざっている状態。都市部ではミクセルの存在が画像分類精度の向上を阻害する要因のひとつとなっている。



## 第V章 結論と今後の展望



## V-1 結論

本研究により、全自動的で都市域をマッピングすることが可能となった。また、各処理過程において、手法あるいはパラメータを検討することにより、精度よく都市域をマッピングする手法を提案することができた。また、各過程で精度検証や出力数値の検討を行った。この結果、確率テーブルにおいて MOD12 の信頼度が高くなっていることなど、本手法による分類の特徴が明らかになった。

さらに、本手法を用いて 103 都市の都市域マッピングを行った。この結果、既存の都市域データと比較して 95%以上のシーンで、既存の土地被覆図と比較して 90%程度のシーンで精度が向上した。本手法を用いた場合、既存のデータと比較して精度の高い全球都市域マップが作成できる可能性が高いことが明らかになった。

また、本手法を用いて作成した都市域マップでは、雲を都市として誤分類する、画像の取得時期によって、畑を都市として誤分類するなどの問題が発生するなど、問題点が明らかになり、精度向上のため改善すべき点を整理することができた。

## V-2 今後の展望

今後の展開として以下のふたつの大きな柱を軸に都市域抽出手法の改善および精度の向上を目指す。

### 1.ASTER 画像のセレクションルールの設定

本研究では、ASTER 画像を手作業で 103 シーン選択して取得したが、今後全球処理を行うにあたって膨大なデータ量を扱う場合、全ての過程を自動的にする必要がある。このため、今回人の手を介した ASTER 画像の選択・入手作業も自動化する必要がある。都市を捉えている衛星画像のうち、都市域分類に適した画像を選択するために、気候帯ごとに都市域抽出に適した時期を検討し、対象地域の雲量データベースを利用しながら、シーンセレクションを自動化する。

### 2.その他の情報の追加

現在は ASTER 画像の可視・近赤外バンドの画像と既存の土地被覆図を利用しているが、ASTER の SWIR や TIR バンドデータの利用、多時期 ASTER データの利用、DEM による thresholds など使用していない ASTER データを利用し、さらなる、手法の改善を行う。

また、近年高解像度衛星画像の入手が容易となったことから、AVNIR2 や SAR などのより高解像データを利用することも可能である。

その他、地名辞典(Gazetteer や Google Earth 上の Populated place)にマークされている都市域ポイントなども併用する。





## 参考文献

Balk, D., Pozzi, F., Yetman, G., Deichmann, U., Nelson, A., 2004. The Distribution of People and the Dimension of Place: Methodologies to Improve the Global Estimation of Urban Extents. ([http://beta.sedac.ciesin.columbia.edu/gpw/docs/UR\\_pap](http://beta.sedac.ciesin.columbia.edu/gpw/docs/UR_pap))

Carlos A. Guerra, Robert W. Snow, Simon I. Hay, "Mapping the global extent of malaria in 2005", *Trends in Parasitology*, Volume 22, Issue 8, August 2006, Pages 353-358.

Elvidge, C. D., Baugh, K. E., Kihn, E. A., Kroehl, H. W., Davis, E. R., & Davis, C. W. (1997). Relation between satellite observed visible? near infrared emissions, population, economic activity and electric power consumption. *International*

Guerra, C. A., W. Snow, R. W., Hay, S. I., 2006. "Mapping the global extent of malaria in 2005", *Trends in Parasitology*, Volume 22, Issue 8, August 2006, Pages 353-358.

IPCC 第2作業部会第4次報告書「気候変化2007：影響、適応及び脆弱性」, 2007  
[www.env.go.jp/earth/ipcc/4th/spm\\_interim-j.pdf](http://www.env.go.jp/earth/ipcc/4th/spm_interim-j.pdf)

Iwao, K., Nishida, K., Kinoshita, T., Yamagata, Y., "Validating land cover maps with Degree Confluence Project information", *GEOPHYSICAL RESEARCH LETTERS*, VOL. 33, L23404, doi:10.1029/2006GL027768, 2006

McMicheal, A., Woodruff, R., Hales, S., "Climate change and human health: present and future risks *The Lancet*, vol.367, Issue 9513, pp.859-869, 2006

McGranahan, G., D. Balk and B. Anderson. 2007. The rising tide: assessing the risks of climate change and human settlements in low elevation coastal zones. *Environment & Urbanization* 19(1): 17-37 (2007). International Institute for Environment

日本リモートセンシング研究会, "図解リモートセンシング", 日本測量協会, 1998.

Sherbinin, A., Balk, D., Yager, K., Jaiteh, M., Pozzi, F., Giri, C., Wannebo, A., 2002. *Social Science Applications of Remote Sensing*  
(<http://sedac.ciesin.columbia.edu/>)

Small, C., Pozzi, F., Elvidge, C.D., 2005. Spatial analysis of global rural urban extent from DMSP-OLS night lights. *Remote Sensing of Environment*, 96, pp. 277-291.

Sutton, P., Roberts, C., Elvidge, C., & Meij, H. (1997). A comparison of nighttime satellite imagery and population density for the continental united states. *Photogrammetric Engineering and Remote Sensing*, 63(11), 1303-1313.

高木幹雄, 下田陽久, “新編 画像解析ハンドブック”, 東京大学出版会, 2004.

United Nations, 2001.

Weber, M., 1964. “都市の類型学”

## 謝辞

柴崎亮介教授： 学部時代とは全く違う分野に進学し、右も左も分からない状態だった私を研究室の一員として暖かく迎えてくださり、理解の遅い私を辛抱強く指導していただいたことにこの場を借りて感謝の意を表したいと思います。先生の研究に対する姿勢から、好奇心を持つことや主体的に物事に取り組むことの大切さを学びました。

産業技術総合研究所 岩男弘毅様： リモートセンシングを学ぶ学生としても、社会の一員としても未熟であった私に、勉強から社会人としての心得まで幅広く、一から丁寧に指導していただきました。岩男様の研究に対する姿勢からコツコツと丁寧に物事を進めることの大切さ、自分の研究を外に発信していくことの大切さを学びました。

トラノアナ勉強会メンバーの皆様： トラノアナでは、学会などの発表前には必ずといっていいほど発表練習をさせていただきました。発表の仕方・発表資料の構成、発表時の心構えなど、大変有用な助言をいただきました。

柴崎研の秘書の方々 久美子さん、ミキさん、かおるさん： 今日まで勉学に打ち込むことができたのは影ながら支えてくれた秘書の方々のおかげです。特に久美子さんには、アルバイトをお願いすることになった際、手続きの方法など、何から何まで丁寧に教えていただきました。

柴崎研・安岡研の研究室メンバー： 柏と駒場に研究室が分かれていることもあり、なかなか交流の機会がもてなかったことが大変残念ですが、研究室のイベントや学会などでは、大変お世話になりました。特に、pookさんには、学会発表前に夜遅くまで発表資料の英語の手直しを手伝ってもらいました。研究室の先輩として勉強を教えていただいただけでなく、旅行の楽しみ方など様々なことを教わりました。

カシワモチ： 今こうして修士論文を書き上げることができたのは一緒に大変な時期を乗り越える仲間がいたからだと思います。特に、外村光さんには様々な場面でお世話になりました。

田中家の家族： ここまで研究を続けることができたのは家族の暖かい応援があったからです。







## 付録