

# 画像解析・画像認識による膜材料劣化状況の自動診断技術の開発

柳室純\*1 具源龍 \*2 瀧澤重志 \*3 加藤直樹 \*4 豊田宏\*5 藤原淳\*6 小田憲史 \*7

## 梗概

膜材料の劣化状況の診断方法として、マイクロSCOPEで撮影されたデジタル画像から残存強度の推定を行う方法が導入されている。本研究では、現在目視によりなされている診断方法を画像解析・画像認識技術を用いて自動化する手法を提案する。具体的には、物理的強度が既知である膜材料のデジタル画像から、色彩情報の統計値、樹脂のクラックや露出した基布の繊維等、劣化に伴い現れる要素の特徴量を抽出して説明変数とし、一般的な重回帰分析の他、データマイニングの分野で提案された手法を用いて予測モデルを作成し、交差検証により予測精度を比較する。実験の結果、実測値と予測値の相関係数が0.9を超える高い精度を有する予測モデルを構築することができた。

## 1 はじめに

### 1.1 背景と動機

建築物に要求される大きな性能に耐久性がある。耐久性とはある時間経過に伴い建築物全体やその部分に生じる劣化に対する抵抗性であるが、その性能には使用される建築材料の種類に拠り大きく個別差があるため、設計・施工・保存管理を通して、建築材料ごとに考慮されねばならない。

最近では柱や梁の代わりとなるような構造部材としての膜材料も注目され研究・開発されているが、一般的に膜材料というと、躯体となる構造部材に対し、後から柔軟に取り付けることができ、純粋な材料単体として建物内外を隔てることのできる数少ない部材である。軽量でかつ適度な強度を持つからこそなせる業である。しかし軽量で柔軟な分、他の部材に比べて劣化に対する抵抗性に変化が生じやすいという特徴がある。

本研究で扱うテント倉庫の膜材料はその一例であり、躯体の鉄骨部材よりも耐久性に劣る膜材料は躯体に対し取り外し可能な形で定着されており、劣化すると交換される。耐久性の材料に拠る個別差が考慮されているために、そのように設計され保存管理されている。しかし交換時期の決定に当たり、設計時に想定される材料個別の耐久性に加え、風や雨等の外的な要因、応力の作用状態等内的な要因から生じる、劣化の個体差を考慮しなくてはならない。そのため、

これらテント倉庫の事後管理の一環として、実際にサンプルを採取することにより膜材料の劣化状況が診断され、その交換時期が決定されている。これまでは主にテントの一部がサンプルとして切り出され強度測定が行われてきたが、ここ数年より膜加工最大手の太陽工業ではマイクロSCOPEによって撮影された画像から残存強度を推定する方法を導入している。

### 1.2 目的と意義

本研究の目的は、膜材料のデジタル画像から物理的強度を推定する予測モデルを作成することである。

一般的に、対象材料の膜材料サンプルを採取し物理的な強度実験を行うことなく劣化状況を推定することを非破壊検査といい、建築材料についていえば、例えば鉄筋コンクリートでは、超音波やX線を用いた検査方法が広く研究され実用化されている。目視による検査方法も同様に普及しており、その高度化された技術として、表面に現れるクラックの検出などにより劣化状況を画像で判定する技術などが研究されている<sup>2),3)</sup>。

しかし今までのところ、膜材料については目視を除いていずれの技術も実用化されていない。膜材料は薄いため、前者の技術の適用が困難であるという理由によるが、逆に材料の表面に劣化の様相が現れるという利点がある。そのような経緯で膜材料の表面の画像を撮影し、その画像を目視により経験的知識を用いて判定するという

\*1 京都大学大学院工学研究科建築学専攻 大学院生 修士課程

\*2 京都大学大学院工学研究科建築学専攻 大学院生 博士課程

\*3 京都大学大学院工学研究科建築学専攻 助手 博士(工学)

\*4 京都大学大学院工学研究科建築学専攻 教授 工学博士

\*5 太陽工業株式会社 空間技術研究所 材料開発グループ グループリーダー 博士(工学)

\*6 太陽工業株式会社 空間技術研究所 空間技術グループ 主任 博士(工学)

\*7 太陽工業株式会社 研究開発本部 博士(工学)




図 1 テント倉庫用膜材料の物理的な構成と性能

方法が導入されたのであるが、さらに画像解析・画像認識技術により劣化状況の推定の自動化が可能となれば、より客観的で有効な非破壊手法の一つになると考えられる。

### 1.3 既往研究

前述の通り画像解析・画像認識による劣化膜材料の強度推定に関する既往研究はないが、文献<sup>1)</sup>で共著者である豊田らは屋外暴露年数と引張残存強度との関係、また屋外暴露試験と促進暴露試験との相関について考察し、暴露条件や暴露年数から強度が推定可能であることを示唆している。

また他の材料の非破壊検査に關係する研究としては、劣化した鉄筋コンクリートの表面に現れるクラックを画像上で検出することを目指したものがいくつかある。例えば文献<sup>2)</sup>では、画像上でクラックを検出した後、クラックの長さ、角度や幅といった単純な形態特徴を画像から抽出し変数とし、強度試験から得られる鉄筋コンクリートの塑性率と比較しており、文献<sup>3)</sup>では、画像上のクラックの分布密度やフラクタル次元などの定量値と、物理的な劣化指標の一つである透水係数との関係を考察している。

本研究は、劣化に関する要素の形態特徴に加え、画像全体に関する色彩統計値を扱っていること、さらにそれらと物理的指標との関係を考察することだけにとどまらず、具体的な残存強度の予測システムを構築している点で新しく、膜構造分野での画像解析・画像認識技術の可能性を大いに示している。

## 2 実験対象

### 2.1 対象膜材料

本研究では、太陽工業で実際に使用している、ポリエステル繊維織物を基布とし表面に塩化ビニル樹脂(以下 PVC と略記)がコーティングされた膜材料を対象とする。この材料は比較的安価でありながら7~10年程度の耐久性を有する<sup>1)</sup>ため広く使用されており、使用実績が多い材料である。対象とする膜材料の性能と構成は図1の通りである。使用した膜材料には、ライトグリーン、ブルー、クリームアイボリーとグレーの4種類の色種別が存在するが、膜材料サンプルの实在状況の關係上、本研究ではグレーのものは扱っていない。

### 2.2 対象画像

#### 2.2.1 画像の仕様

本研究で用いたデジタル画像は、全体の画素(pixel)数が横608×縦464=282,112(pixel)となっている。倍率は140倍と40倍の2種類あり、それぞれ約横2mm幅と6mm幅の対象物が撮影できるため、各々おおよそ0.0033(mm/pixel)、0.010(mm/pixel)の解像度

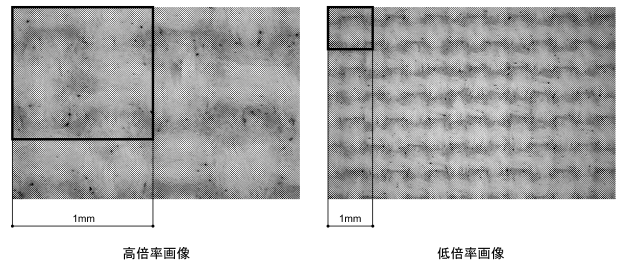


図 2 撮影可能な画像の倍率




図 3 予測値の採り方の種類

を有する。前者を高倍率画像とし、後者を低倍率画像とする(図2)。

上記の画像を用いて、目視によりある程度の画像の認識と残存引張強度の推定が可能であることがわかっているため、電子顕微鏡などで撮影されたさらに高倍率の画像は、必ずしも必要でないと考えられる。そこで本研究では、目視時に用いられる倍率の画像を用いることにし、その判定の厳密化と自動化に主眼を置く。

#### 2.2.2 サンプル数

引張試験を行った5cm×5cmの膜材料サンプルが45枚あり、1枚の膜材料サンプルにつき2種類の倍率で各々5枚ずつランダムに別の場所をマイクロSCOPEで撮影し、合計で450枚の画像サンプルを用意した。ただし、目視で確認できる範囲で同じ膜材料サンプル上で見た目のバラツキが生じている場合は、そのバラツキが5枚に含まれるように5枚の画像サンプルを撮影した。

各倍率で225枚のモデル構築用画像サンプルがあり、予測モデル作成過程での検証法は225枚の画像サンプル全てを用いた交差検証にもとづいている。

実験では、各膜材料サンプルに対し、5枚の画像サンプルとなる画像を用いてモデルの構築を行うことになるが、最終的にその予測値をどのように扱うべきかを考察する。(1)各膜材料サンプルに対する5枚の画像サンプルを各々別に扱い、新しい対象画像サンプルの採取も1枚でよいことを前提に予測値を個別に扱う方法、(2)5枚もしくは複数の画像サンプルを採取することを前提として、最小と最大の予測値を外れ値とみなし、残った予測値の平均をその膜材料サンプルの予測値とする方法、(3)画像サンプルのバラツキが有る場合、劣化状況は劣化の要因が発生しているという事実(部分)に強く牽引されるという推測に基づき、かつ安全側になるよう最小値をとる方法、の3つについて考える(図3)。




図 4 画像サンプルの平均引張残存強度と劣化度ランクの度数

### 2.3 属性と目的変数

膜材料サンプルの属性として、縦方向引張残存強度、横方向引張残存強度、縦方向引張裂残存強度、横方向引張裂残存強度、使用年数、色種別、場所（膜材料サンプルを採取した建築物の所在地）、大まかな部位が蓄積されているが、全ての膜材料サンプルが共通して有する項目は縦方向引張残存強度、横方向引張残存強度、色種別に限られている。膜材料サンプルの個体差を考慮すると、時間経過の中で使用年数、場所、大まかな部位という、条件としての属性の影響は、採取時の膜材料サンプルの性質に、すなわち採取された画像サンプルの画像中に反映されていると考えるべきであるため、説明変数に用いる必要はないと考えられる。

よって、構造計算上最も重要である<sup>1)</sup>縦方向引張残存強度、横方向引張残存強度の平均を採って、平均引張残存強度としこれを目的変数（予測変数）とする。単位はパーセンテージ（%）で表され、未使用時の強度に対する残存強度の割合を意味する。また色種別に関しては、ライトグリーンが膜材料サンプル数で 43 枚、その他が 2 枚と圧倒的な偏りがあるため、各々について別々の予測モデルは構築せず、また属性としても使用していない。平均引張残存強度については、図 4 で示すような分布となっており、予測モデルの構築には比較的十分なデータが与えられたと考える。また現場での需要として劣化度のランクの出力が望まれているため、平均引張残存強度の 66.6%と 33.3%を境に A、B と C のランクを用意しそれらを予測精度の評価基準の一つとして用いる。

### 2.4 画像の性格と予測手法の選択

サンプルとして用いた画像はどういった性格を持つか、加えてその性格と目的変数との関係性が如何なるものかを考えることで、最適な予測手法の選択を試みる。画像の分野において、例えば画像上のあるオブジェクトが検出されそのオブジェクトが何で有るかを判定するような性格の画像があり、そういった画像の中には検出の対象となるオブジェクトの全体が現れていることが大半である。このように目的変数が a、b または c となるような判定が目的となる場合、検出対象のオブジェクトの形状や位置関係などの幾何的情報を定量化した値の相対的な類似性の比較等により、モデル構築がなされる。

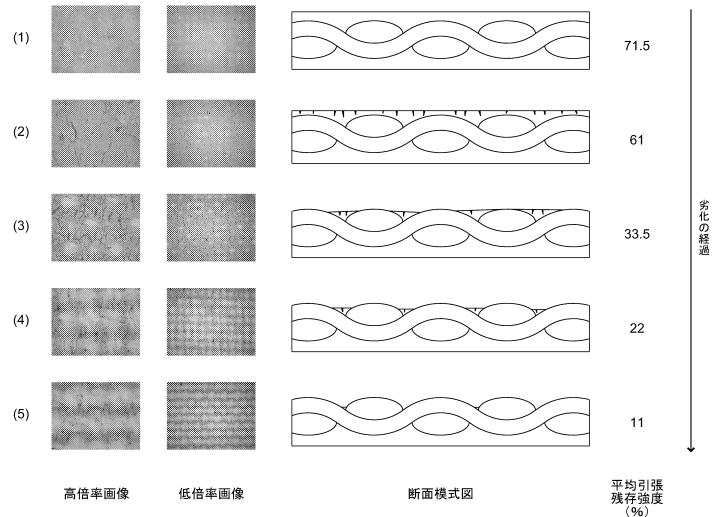


図 5 劣化に伴う膜材料の変化

一方、本研究の対象となる画像の場合、画像で捉えている範囲は膜材料という対象の一部分の拡大図である。また膜材料の性質上、上下左右に同じパターンが繰り返すと考えられるため、パターンが一樣な画像、すなわちテクスチャ画像といえることができる。よって、画像には劣化過程に伴う膜材料の連続的変化の断面が捕らえられており、画像上には満遍なくその影響が現れ、各々の画素に反映されていると考えられる。

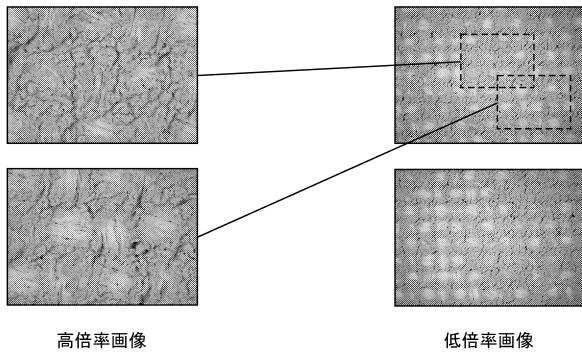
このような性格の画像に対し、目的変数もまた連続的に変化する数値データであることを考慮すると、画素の性質を画像全体に対して網羅的に分析することが強度予測に重要な手法になると考えられる。すなわち、画像の各々の画素の色彩に関する統計的指標を用いることが非常に妥当な手法の一つであることが推測される。

鉄筋コンクリートでは劣化に伴い現れる要素はクラックであり、背景となるコンクリート部分から抽出したクラックの特徴量を主要要素として取り扱うが、膜材料では以下のような 3 つの要素を取り扱う。(1) 濃い色をしており劣化の少ない画像上で大きな面を占める PVC コーティング（以下コーティングと略記）、(2) 白色で面状に現れている繊維、(3) 黒色で線状に現れているクラックの 3 要素である。


これら要素が残存引張強度に関連しているであろうという推測を元に、後述するような目視判定時の人間の視覚的な判断方法に近づけること、膜材料の物理的な観点を盛り込むことを視野に入れ、色彩情報の統計値だけでは扱えない、要素の形態特徴の定量化も行う。

### 2.5 劣化に伴う膜材料の変化の考察

図 5 に実際の画像を例に挙げ、劣化に伴う画像上の膜材料の変化、特に各要素の変化について触れながら説明する。これらは目視による判定時に用いられている知識であり、これらを正確に考察することが判定の自動化に際して有力となる。図 5 中では上から下に劣化度の小さいものから大きいもの（平均引張残存強度が大きいものから小さいもの）という順番に画像が並んでいる。また断面模式図で劣化の経過にともない断面がどのような過程をたどっているのかを示している。



(1) 高倍率画像と低倍率画像の比較



低倍率画像 平均引張残存強度 19%

(2) 画像の性質に違いのある例

図 6 同じ膜材料サンプルから撮影された画像サンプルの比較

画像上において、(1) 全体がコーティングに覆われている状態から、(2) クラックが現れ、(3) 縦糸と横糸が交わる場所で繊維が所々に露出し、(4) その領域が徐々に広がり、さらに劣化が進むと隣の領域と繋がり、(5) 多くの場所で連続するようになる。

## 2.6 倍率の選択

図 6 に示す通り白く面状に見られる繊維に関して、高倍率の画像には見られない配置のパラツキが低倍率の画像には見られるのがわかる。つまり高倍率の画像ではその膜材料サンプル上の撮影箇所によって画像の性質に違いがでてしまう。一方低倍率の画像ではそのパラツキの影響も含んだ膜材料サンプルの性質が画像の性質に反映されると考えられる。また、3 節の要素に関する形態特徴のところでも詳しく説明するが、形態特徴の現れるピッチが繊維の糸の間隔に依存していると見受けられるため、そのピッチと画像の大きさとの差が大きいほうが正確な定量化を行うために良好と考えられる。実際には同じ膜材料サンプルを撮影した低倍率画像の画像サンプル間でも撮影箇所によって違いが見られるが、先述の通り予測値の取り扱い方を工夫することで、画像サンプル間の違いを考慮したモデルになるようにする。よって実験では低倍率の画像のみを扱うことにし、最終的な予測モデルも低倍率の画像に対応したものになっている。

## 3 提案モデル

### 3.1 提案モデルの流れ

図 7 に示すとおり、提案モデルはまず全画素に関する特徴として、色彩情報の統計値、要素に関する特徴として各要素の形態特徴についての定量値を取り出し、最適な変数を選択した後、回帰分析を施すという流れである。色彩情報としては一般的な統計手法で代表値

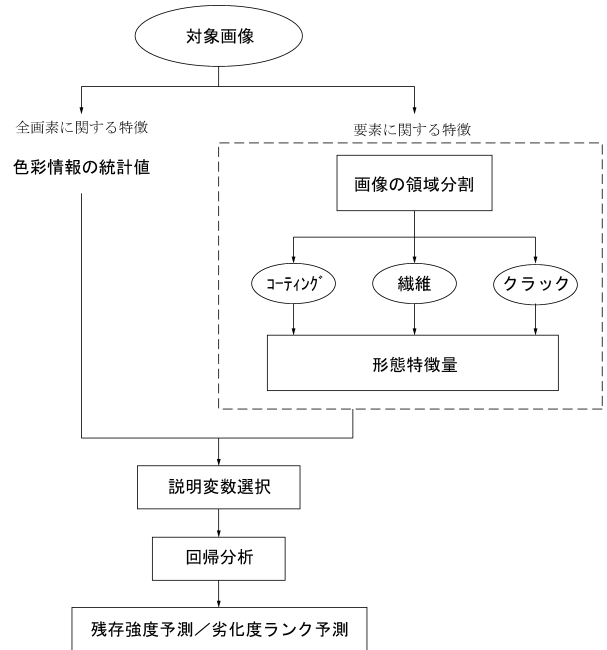


図 7 提案モデルの流れ

を取り出し説明変数とする。要素に関する特徴量を得るためには領域分割を行い要素を抽出する必要があり、一般的なクラスタリング手法を用いて全画素を、コーティング、繊維、クラックの要素に分類する。

そして、縦糸と横糸が交わる所でコーティングが擦り減り繊維がスポット状に露出し始めるという性質を考慮し、画像上の糸の位置にグリッドに置き、要素の形態特徴を精密に行う手法を提案する。

### 3.2 全画素に関する特徴

#### 3.2.1 色彩情報の統計値

色彩情報として、RGB、HSV、XYZ、 $L^*a^*b^*$  の 4 つの表色系を用い、画像における全ての画素の各表色系の 3 つの指標に対応する値を求める。1 つの対象画像に関する代表値として、それぞれの指標の値に対して、平均 (mean)、標準偏差 (std)、最頻値 (mode)、最大値 (max)、最小値 (min)、中央値 (median) を算出する。先に述べたとおり、本研究で扱う目的変数は、ある入力画像があらかじめ分類されたある種類に同定されるような分類データではなく、連続的な数値データである。ヒストグラムの分布の仕方や相関係数の大きさにより説明力のありそうな変数についてある程度の推測はできるが、目視による診断の際に用いられる知識では、どの説明変数にどのような説明力が潜んでいるかは特定できない。よって、あらゆる変数に目的変数に対する寄与の可能性を十分に残すため、最小限の加工を施した十分に多いとみなせる指標のデータを用意する。

#### 3.3 要素に関する特徴

要素 (コーティング、繊維、クラック) の特徴を得るためには、物理的な構成を踏まえた劣化過程の考察を可能な限り行う必要がある。引張残存強度の大部分を担っているのはポリエステル繊維織物であるが、その上下部のコーティングとの複合効果で引張に対してさらに高い強度を保持する<sup>4)</sup>ため、コーティングが剥がれる程、残存強

度は低下する。つまり提示した要素は3つが並列的に並んだ独立関係にあるものではなく、画像上ではコーティングの剥がれが、繊維またはクラックという形でコーティングの上に現れているという従属関係にある。またクラックは剥がれの初期段階であり、劣化が進んで繊維に進化するという関係がある。具体的にはこれら2つの要素を劣化に伴い現れる要素とし特徴量を取り出すことで、相対的にコーティングの特徴を考慮して3つの要素を総合的に扱う。

### 3.3.1 領域分割

領域分割とは、全画素を対象となる異なるオブジェクト（クラス）にクラスタリングし同定することである。本稿では、一般的なクラスタリング手法の教師あり判別手法である、K最近傍決定則（K-Nearest Neighbor Method）<sup>5)</sup>および、決定木手法（Decision tree）<sup>6)</sup>、教師なし判別手法であるk-means法<sup>7)</sup>を用いて実験し精度の高いものを用いる。

K最近傍決定則とは、対象となる入力データから予め用意した目的変数が既知の全学習データまでの距離を測り、近い方からK個のデータを用いて多数決判断をし、目的変数の判別を行う手法である。特徴として色彩特徴で用いた4つの表色系RGB、HSV、XYZ、L\*a\*b\*の各々3値を用い、距離尺度としてユークリッド距離を用いる。二つの特徴ベクトルを  $X = (x_1, x_2, \dots, x_n)$ 、 $Y = (y_1, y_2, \dots, y_n)$  とするとユークリッド距離は

$$\sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

となる（図8）。

決定木手法とは各特徴の値が閾値より大か小かの組み合わせにより分類する多段階的な判別手法である。特徴として4つの表色系各々3値の組み合わせと、その値全てを合わせた12値の組み合わせを用いる。

k-means法とは指定したn個のクラスにクラスタリングする手法である。特徴空間内における全対象サンプルから適当に選ばれたクラスターの中心位置を初期値とし、全対象サンプルを特徴空間上で最も近い中心位置のサンプルに同定する。各クラスターごとのサンプルの平均値を求め、それを新たな中心位置に更新するという操作を繰り返し、中心位置が更新されなくなったらそのときのクラスターを出力する。k最近傍決定則と同じく4つの表色系RGB、HSV、XYZ、L\*a\*b\*の各々3値を用いる。領域を統合すること前提とし、必要なクラスター数より以上の  $n = 3, 4, 5$  で実験を行う。

実際にこれらの手法により得られた領域分割された要素の予測領域の例を図10示す。

### 3.3.2 2値画像処理

繊維として抽出された予測領域からノイズを除去し、適切に連結した領域を最終的な繊維の領域とする。具体的には対象領域が白で背景が黒で表された2値化画像を対象領域を収縮させて作り、次に画像全体にガウス関数を用いた平滑化を施し再度2値化し、その後対象領域を膨張させる（図9）。

ここで収縮とは与えられた対象画素の近傍が黒であるか否かを判定して、連結成分の境界画素を全て取り除いて1画素分小さくする処理であり、逆に膨張とは近傍が白であるか否かを判定して境界画素を1画素分大きくする処理である。本稿では4近傍を調べることに

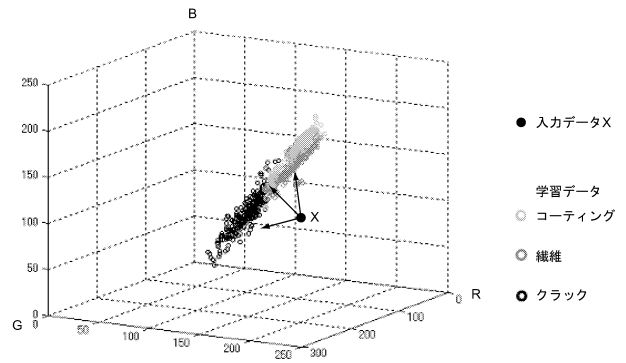


図8 K最近傍決定則による特徴空間内での判別の例




図9 2値画像処理を施した繊維の領域画像の例

し、2回の収縮、膨張をし、幅が4以下である領域をノイズとみなし除去する。

ガウス関数による平滑化とはガウス関数

$$G(x, y) \equiv \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (2)$$

の標準偏差  $\sigma$  をパラメータとして平滑化の度合いを解像度を調整することで変更できる操作である。ノイズと考えられる小さな単位の要素をパラメータを用いて排除でき、大局的な要素の構造を得ることができる。

### 3.3.3 繊維の構成とグリッド

目視による判定時の主な判断材料であり、画像上の特徴に比較的寄与力があると考えられる繊維は、劣化すると縦糸と横糸に沿って表面に現れる。膜材料の画像はテクスチャ画像と考えられると述べたが、画像上で要素の特徴は完全に満遍なく分布しているのではなく、縦糸と横糸の影響で扱う画像の大きさに対して無視できないピッチで特徴が分布すると考えられる。その繊維の物理的構成に基づいて対象領域のフレーム取りと分割、つまりグリッドを導入し、膜材料サンプルごとに個体差があるピッチに合わせた対象領域を決定することで、判断基盤に正確さをもたせることができる。

繊維は、鉛直方向に見て織られた縦糸と横糸が交差する部分からスポット状に露出する。コーティングは上部からほぼ同等に剥がれて減っていくが、糸の交差部分で水平方向に見て織物が上下に孕んでいるために、必然的にその部分で繊維が早く露出することになる。この性質を考えると、画像上で露出し始めのスポット状の繊維の領域は、ほぼ縦糸と横糸の交差点の位置にあると考えられる。よって繊維が露出した画像に関しては繊維の占める領域の位置と形状の情報から、水平面上の縦糸と横糸の位置が推測できる。ここにグリッドを引き、そのグリッドに縦糸と横糸を代表させ、そこから物理的構成と劣化過程を踏まえた様々な特徴を抽出することを考える。

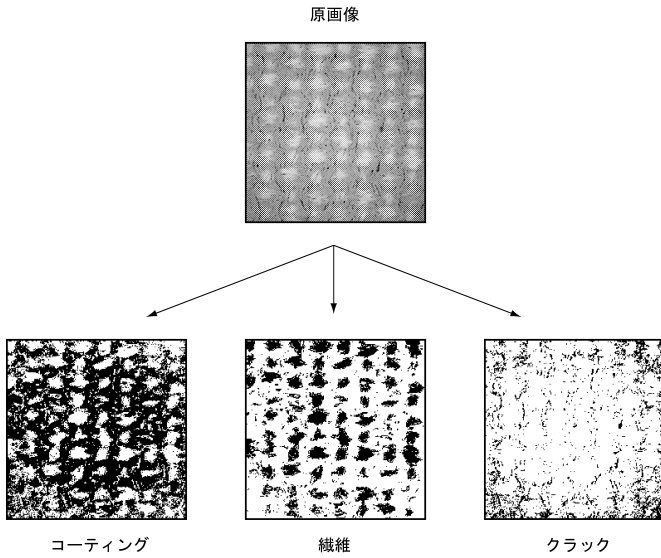


図 10 領域分割された要素の予測領域の例




図 11 断面模式図：交差点の位置の検出

具体的には、横方向（以下  $x$  方向）縦方向（以下  $y$  方向）とも等間隔に糸が並んでいると考え、グリッドの幅をそれぞれ  $a, b$  とし配置する。交点  $(i, j)$  を中心に  $x$  方向に幅  $a$ 、 $y$  方向に幅  $b$  を持つ長方形を交点  $(i, j)$  のセル  $A_{ij}$  とする。  $6 \times 6$  の交点の領域  $\sum_{i=1}^6 \sum_{j=1}^6 A_{ij}$  を含む領域を要素の特徴を抽出する対象領域とする（図 13）。

### 3.3.4 交差点の位置の検出

グリッドを配置するために、2 値画像処理を施した領域画像から交差点の位置を推定する。糸は円柱が平たく変形したような断面をしており、また水平方向に見て交差部分毎に上下交互に波打って位置する性質により、グリッドの交差部分は糸の最も隆起した部分にくると考えられる。例えば平面上で横方向（以下  $x$  方向とする。また縦方向を  $y$  方向とする）の劣化して繊維が露出した膜材料の断面を模式的に考えたとき、その切断平面と繊維の領域の交線は領域の境界を閉曲線としたときの弦である。最も隆起した部分を通る切断面と領域の交線が、 $x$  方向に最大長である弦であると考えられる（図 11）。よって、 $x$  方向と  $y$  方向それぞれについて繊維の領域に属する画素の度数分布を求め、その度数が多い位置ほど交差部分の位置らしいという性質を用いて最もそれらしい場所にグリッドを配置する（図 12）。

交差点の位置の検出、そしてグリッドの配置は自動化することを目標としているが、本研究では、交差点の位置を手動で検出し、  $6 \times 6 = 36$  の交差点を含むような外側の枠を決定している。

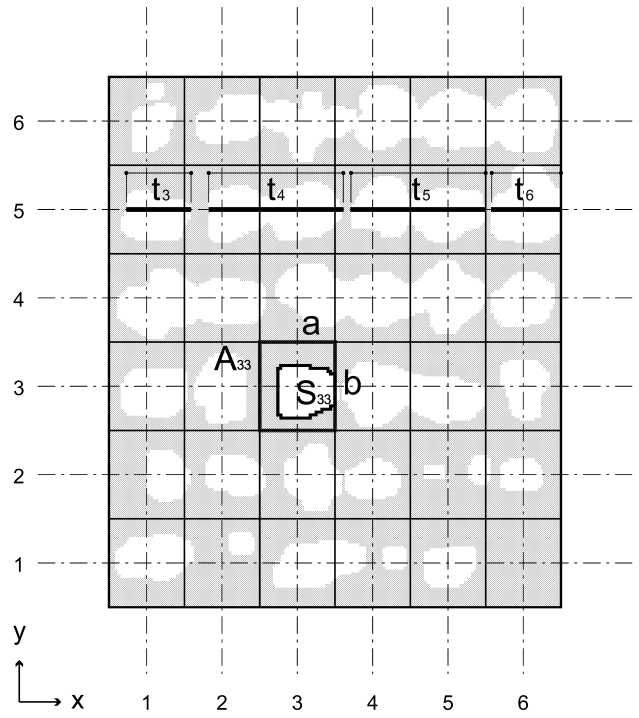


図 13 特徴量抽出の対象領域と繊維の特徴量

### 3.3.5 繊維の特徴量

画像上の同面積から取り出すのではなく、同じ交点の個数で括られた枠組みで特徴量を抽出する。以下のものを繊維に関する特徴量とし説明変数とする（図 13）。

セル  $A_{ij}$  における繊維の面積を  $S_{ij}$  とする。

- $S_{ij} > 0$ （繊維領域が存在する）のセル  $A_{ij}$  の個数、
- 面積の平均値  $\sum S_{ij}/36$  と最大値  $S_{max}$ 、
- 面積  $S_{ij}$  の標準偏差  $D_a$ 、
- 一つの連結する繊維領域の  $x$  方向のグリッド上における長さ  $t_{im}$  の平均値  $\sum_{im} t_{im}/im$ 、  
 ( $im$  は一つの連結する繊維の  $x$  方向のグリッド上における個数、 $y$  方向は  $t_{jm}$  の平均値  $\sum_{jm} t_{jm}/jm$ ) と  $x$  方向  $y$  方向のうちの最大値  $\max(\sum_{im} t_{im}/im, \sum_{jm} t_{jm}/jm)$ 。

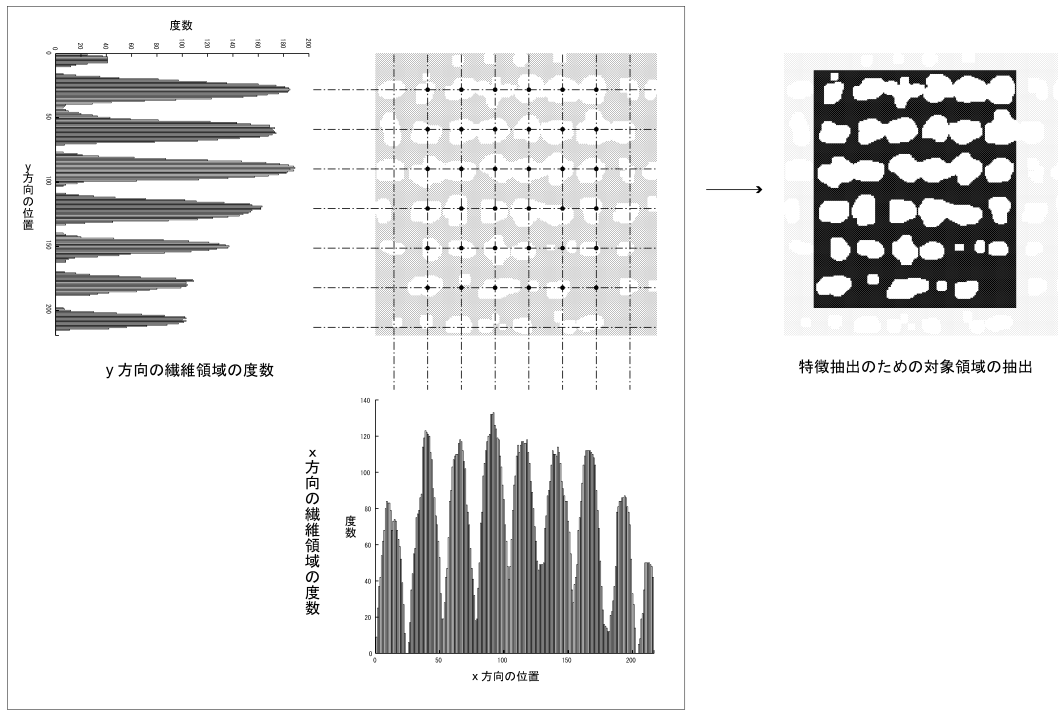
### 3.3.6 クラックの特徴量

クラックは前述の通り、コーティングに対する剥がれの初期段階であるため、必ず画像上ではコーティングの領域の上にある。よって、領域分割でクラックと予測された領域を、繊維の領域でマスキングしノイズと考えられる部分を除去し、正確なクラックの領域を得る。

クラックはコーティング部全体に、画像の大きさに対して無視できるピッチでかつほぼ満遍なく分布しているため、クラック出現の度合いを測る指標として以下のものを特徴量として取り出し説明変数とする。

- クラックの個数密度  $n_c/S_s$ 、
- クラックの占める面積の割合  $S_c/S_s$ 。

ただし、 $n_c$  はクラックの個数、 $S_s$  はコーティング部の面積、 $S_c$  はクラックの面積とする。



グリッドの位置推定

図 12 グリッドの配置と対象領域の抽出

### 3.4 説明変数選択

解析を行う前に、取り出された初期説明変数を選択して、冗長的または目的変数とは無関係と考えられる変数を取り除くことで精度の向上と計算時間の高速化を計る。さらに現学習データに対するオーバーフィッティングを防ぎロバストなモデルの作成を試みる狙いがある。ここでは以下に説明する CFs 評価法を用いて、説明変数の組み合わせを評価し、最良優先探索を用いてよりよい組み合わせを見つけ出す。入力画像から取り出された説明変数を並べたものを、特徴ベクトルと呼ぶ。説明変数選択とはこの特徴ベクトルで張られる多次元の特徴空間を低次元化してゆくことである。

#### 3.4.1 CFs 評価法 (Correlation-based Feature subset Evaluation)<sup>8)</sup>

説明変数選択の評価関数は、いかに特徴同士が強い相関関係にあるかということを示す指標とする CFs 評価法を用いて決定する。良い特徴ベクトルは目的変数に対してより高い相関と予兆性をもち、なおかつ特徴間で相関が小さく予兆性のないものである、という原則に従って、評価関数を

$$r_{zc} = \sqrt{\frac{k\bar{r}_{zi}}{k + k(k-1)\bar{r}_{ii}}} \quad (3)$$

のように定式化する。ただし、評価関数として  $r_{zc}$  は特徴ベクトルと目的変数の相関を表し、 $k$  が総特徴数、 $\bar{r}_{zi}$  は各特徴と目的変数の相関の平均、 $\bar{r}_{ii}$  は特徴間の相関の平均を表す。

#### 3.4.2 最良優先探索 (Best First)

最良優先探索とは、高速であるが局所解に陥りやすい山登り法 (Greedy hill-climbing) にバックトラック機能 (Backtracking Facility) を付加し拡張した手法<sup>5)</sup>である。今回の場合は局所的な変化 (1つの特徴の付加と削除を施したノードを前後に持つ) を考慮してパスが繋がれた探索木を対象としている。

### 3.5 回帰分析

選択された説明変数を用いて回帰分析を行う。ここでは目的変数が説明変数の線形和で得られる重回帰分析、重回帰式を葉にもつ決定木ベースの M5P 分析を用いる。

重回帰分析は、多くの分野で用いられている代表的な統計手法であり、他の様々な応用手法の比較対象としても妥当な手法であるといえる。本研究でも重回帰分析は、本対象に適当な一手法であることに加え、後述する M5P 分析に対する比較対象としても用いる。重回帰分析による予測モデルは、強度予測値すなわち目的変数が説明変数全てを含む一つの線形式によって得られ、あらゆる残存強度に対して同じ回帰式が与えられる。それに対し複数の重回帰式が条件式に応じて与えられる M5P 分析は、重回帰分析を発展させた手法と捉えることができ、2つを比べてその効果を検討する。

続いて M5P 分析を本対象に用いる意義を以下に述べる。膜材料の劣化に伴う要素に関して、繊維ではある残存強度の範囲でしか現れない、クラックでは同様のことが当てはまることに加え残存強度によって意味合いが変わる、といった非線形的な推測をすることができる。そういった特徴量から得られた変数に対して、変数についての条件式によって最適な重回帰式を与えてゆく M5P 分析のモデルは、人による解釈に近い方法が適切に盛り込まれた本対象に妥当な手法であると考えられる。

#### 3.5.1 重回帰分析 (Linear Regression)

重回帰分析では、未知パラメータを  $b_0, b_1, \dots, b_p$  とすると回帰モデルが

$$Y = b_0 + b_1x_1 + b_2x_2 + \dots + b_px_p \quad (4)$$

と線形和で表され、最小2乗推定の原理に従ってパラメータが推定される。 $Y_i$  を実測値とすると、観測値と予測値の残差の2乗和は

$$e = \sum_{i=1}^n \{Y_i - (b_0 + b_1x_{i1} + b_2x_{i2} + \dots + b_px_{ip})\}^2 \quad (5)$$

のように表され、 $e$  が最小の値をとるように係数  $b_0, b_1, \dots, b_p$  が決定されてゆく。

### 3.5.2 M5P (tree-based piecewise linear models) 分析<sup>9)</sup>

決定木は比較的効率的で単純な判別分析として有名であるが、この判別手法をベースとして、最終的には数値データを予測値として得ることを可能にした手法が M5P 分析である。まず第一段階として、初期モデルとなる木を構成するために、学習データの集合を  $T$  とし、それに検定を施し分割する。まず  $T$  の目的変数の標準偏差  $sd(T)$  を計算し、推定誤差を

$$\Delta error = sd(T) - \sum_i \frac{|T_i|}{|T|} \times sd(T_i) \quad (6)$$

のように定式化する。ただし、 $T_i$  は検定で得られた  $i$  番目の部分集合で  $sd(T_i)$  は  $T_i$  の標準偏差である。初期モデル木が生成された後、誤差推定、線形モデル、線形モデルの単純化、枝の剪定の作業が施されモデル木が完成される。

なお、M5P 分析では分析過程で自動的に変数が絞り込まれるため、全ての説明変数を用いてモデル構築をする。

## 4 実験手順

### 4.1 領域分割

3つの要素への領域分割の前処理として、現画像を  $6 \times 6 = 36$  のグリッドにより規定される領域  $\sum_{i=1}^6 \sum_{j=1}^6 A_{ij}$  を過不足なく含むよう  $448 \times 448 = 200,704$  (pixel) の正方形の画像に切り抜いた。得られた画像に対し、原画像の  $1/2^{m-1}$  ( $m = 1, 2, 3$ ) の解像度について、3つの手法で実験を行った。

その結果、精度は K 最近傍決定則と決定木手法が画像サンプルにより精度に差があるがほぼ同程度とみなされる結果が得られた。その後の2値化画像処理での効果を踏まえると、共に十分な精度の結果が得られたといえる。なお k-means 法では、決められた個数のクラスタにクラスタリングすることを動的に行うため、画像サンプルによっても動的な同定結果が得られる。よって後処理としてクラスタの統合やクラスタの交換が必要になり、非常に煩雑な上に正確な結果が得られる確信度が低いと考えられるため、k-means 法を採用しないことにした。



計算時間と、精度とのトレードオフを考慮して、解像度は  $m = 2$  を選択肢し、4表色系の各々3値の合計12値の組み合わせを変数として決定木手法を適用した結果を採用した。

### 4.2 予測精度の検証方法

初期説明変数として全画素に関する色彩特徴から説明変数が72個、要素に関する形態特徴から説明変数8個が得られており、まず各々別々に実験を行い、その後で両方の変数を合わせて実験を行った。予測精度は、同じ膜材料サンプルから撮影した画像5枚を試験データとし、それ以外の220枚を学習データとして作成した予測モデルで計算し得た予測値と予め得られている実測値を比較することを、異なる45枚の画像に関して繰り返す行い、leave-one-outにより行った。

表1 説明変数選択の結果

色彩特徴			形態特徴
R_mean	S_mean	Z_mean	Fab_mean
R_std	S_std	Z_std	Fab_std
R_mode	S_mode	Z_mode	Fab_max
R_max	S_max	Z_max	Fab_ongrid_max
R_min	S_min	Z_min	Fab_ongrid_mean
R_median	S_median	Z_median	Fab_num
G_mean	V_mean	L_mean	Cra_density
G_std	V_std	L_std	Cra_ratio
G_mode	V_mode	L_mode	
G_max	V_max	L_max	Fab_mean
G_min	V_min	L_min	セルに属する領域の面積の平均
G_median	V_median	L_median	Fab_std
B_mean	X_mean	a_mean	セルに属する領域の面積の標準偏差
B_std	X_std	a_std	Fab_max
B_mode	X_mode	a_mode	セルに属する領域の面積の最大値
B_max	X_max	a_max	Fab_ongrid_max
B_min	X_min	a_min	連結する領域のグリッド上の長さの平均
B_median	X_median	a_median	Fab_ongrid_mean
H_mean	Y_mean	b_mean	連結する領域のグリッド上の長さの平均でx方向とy方向のうち大きい方の値
H_std	Y_std	b_std	Fab_num
H_mode	Y_mode	b_mode	繊維領域が存在するセルの数
H_max	Y_max	b_max	Cra_density
H_min	Y_min	b_min	クラックの個数密度
H_median	Y_median	b_median	Cra_ratio
			クラックの面積の割合

 色彩または形態特徴別々に説明変数選択を施して選択された変数  
 色彩と形態特徴を合わせて説明変数選択を施して選択された変数

### 4.3 説明変数選択

CFs 評価法 (Correlation-based Feature subset Evaluation) と最良優先探索 (Best First) を用いた説明変数選択によって選択された説明変数を表1に示す。

まず色彩特徴についての考察をする。色彩特徴から得られた説明変数のみを初期説明変数とした場合は38個、形態特徴から得られた説明変数と統合した場合は41個の説明変数が選択された。標準偏差が全体で比較的多く選択されており、これは最初は綺麗で色むらの無い膜材料の画像上に、劣化に伴う要素である繊維、クラック、また要素の形態特徴では扱っていない汚れなどが現れてきて、劣化に伴い色のバラツキが出てくるからと推測できる。

要素に関する形態特徴については、形態特徴から得られた説明変数のみを初期変数とする場合は6個、色彩特徴から得られた説明変数と統合した場合も6個の変数が選択された。初期説明変数が少ないことも理由に挙げられるが、多くの変数がそれぞれ強度に相関のある寄与力を備えていることがわかる。特筆すべき点として、表中では Fab\_mean と表される繊維の単純な対象領域内の面積の量で表される変数よりも、Fab\_std で表されるグリッドの一つの交点に属する面積のバラツキや、Fab\_max で表されるグリッドの一つの交点に属する面積の最大値が、平均残存引張強度に寄与力があることなどがある。これらはグリッドの配置により初めて得られる説明変数であるため、グリッドの配置を考慮して得られる属性が効果的に働いていると推測される。



表 2 分析手法と用いる特徴による予測モデルの精度の違い

モデルの構築に用いた特徴量	重回帰分析		M5P分析	
	相関係数	平均絶対誤差	相関係数	平均絶対誤差
色彩特徴	0.906	7.258	0.835	8.358
形態特徴	0.93	6.345	0.929	6.03
色彩特徴+形態特徴	0.928	6.436	0.93	6.091

表 3 予測値の採り方による予測モデルの精度の違い

予測値の採り方	重回帰分析		M5P分析	
	相関係数	平均絶対誤差	相関係数	平均絶対誤差
全てのサンプル	0.928	6.436	0.930	6.091
最小と最大を除外したサンプルの平均値	0.939	5.970	0.944	5.708
最小のサンプル	0.937	6.930	0.924	6.508

## 5 実験結果

上で得られた説明変数を用いて、重回帰分析と M5P 分析を行った。それらに関する結果を、平均引張残存強度の実測値と予測値との絶対誤差の相関係数と平均絶対誤差で表 2 に示す。平均絶対誤差は、そのモデルによって得られる新たな試験データの予測値が、実際の平均引張残存強度から絶対値でどの程度の差があるかを表した実用的な精度の指標である。

さらに画像サンプルによる精度のバラツキや個々画像サンプルの推定結果を把握するために図 14 に予測結果の分布図をモデル別に示す。横軸が平均引張残存強度の実測値を縦軸は予測値を表す。劣化度ランクの予測精度は、3×3 のマトリクスに分布図上の度数を表示することにより示しており、網掛けがかかっている部分の数値が劣化度ランクの同定に成功しているサンプル数である。平均引張残存強度に対し劣化度ランクの予測精度が必ずしも単調に変化しないのは、平均引張残存強度が連続的な数値であるのに対し、劣化度ランクが離散的な値であることに起因する。

### 5.1 構築したモデルの予測精度の比較

色彩特徴と形態特徴から得られる変数を持つ統合モデルについては、M5P 分析が重回帰分析を上回り、このモデルが全モデルで最も高い予測精度を有する結果となった。

色彩特徴から得られる変数を持つモデルでは両分析間の予測精度に大きな差があるが、統合モデルではその予測精度の差を大幅に縮め逆転しているのがわかる。これは、M5P 分析の要点である、複数の異なる重回帰式を条件に従って分配するという局所的な最適性を有するモデルの性質に、形態特徴による変数が適合した結果であると推測される。そしてこれは目視により近い挙動をしていることから発展可能性のある予測モデルとして捉えることができる。

### 5.2 予測値の採り方についての比較

予測精度の最も高かった統合モデルについて、図 3 で示した、同じ膜材料サンプルに対する 5 つ画像サンプルを別々に扱う方法、最小と最大を除外した 3 つの値の平均値を採る方法、最小を採る方法の 3 つの方法で予測精度を比較した。

最小と最大を除外したサンプルの平均値を採った 2 つめの方法が、両分析ともに高い予測精度を得ていることがわかる。前述の通り同じ膜材料サンプルから撮影した、画像サンプル 5 枚の間にはバラツキがありその主要因は繊維の分布に関するバラツキであると考えられる。よって繊維の領域が見られ始める、平均引張残存強度 50 (%) 以下で、大部分で繊維の領域が連結する 15 (%) 以上の間に、その

バラツキが顕著に見られ、それらによる悪影響を解消できた結果であると推測できる。

また、先に述べた通り最小の値をとることで安全側の結果が得られることが、劣化度ランクの同定結果により示されている。実際図中右下、モデル C で示されるように、唯一つの膜材料サンプルも危険側の結果を予測していない。

ただし現段階のモデルにおいては、2 つめの方法でより正確で危険度の低い予測値が得られることが推測されるため、実用に当たっても複数の画像サンプルを採取することは、十分に意義のあることだと考えられる。また同時にこれらのバラツキを踏まえて、学習モデルに妥当な画像サンプルを検討することにも利用できる。

## 6 結論と今後の課題

膜材料の劣化状況の診断技術として実用に耐え得る、十分な予測精度を有するモデルを構築することができる可能性を示した。M5P 分析を用いた統合モデルの予測精度が最も高く、その妥当性についても検討することができた。現状では説明変数選択を施した色彩特徴から得られた説明変数によるモデルの構築、予測結果を出力する自動化システムが完成しており、膜材料に対する非破壊試験の一手法として、画像解析/認識を用いた膜材料劣化状況の自動診断技術の可能性を示すことができたといえる。

引張試験が完了した膜材料によって得られた画像サンプルには、図 4 でわかるように平均引張残存強度についてバラツキがあるため、今後新たな膜材料による学習用の画像サンプルの追加が期待される。それら学習サンプルの追加や、属性の追加によって、劣化過程をより詳細に反映した画像サンプルのデータセットが得られたら、先述した理由により M5P 分析がより効果的に働くことも推測される。

今後の課題としては、要素の形態特徴の追加により予測精度が向上したことから、グリッドの配置による対象領域を指定することに意義があることが示されたため、グリッドの配置を自動化しこのシステムを完成させることが望まれる。

予測値の取り扱いについて検討したことと同様に、続いて学習サンプルの取り扱いについても検討する必要がある、より妥当な画像サンプルで予測モデルの学習をさせることを試みる。具体的には、膜材料サンプルのどの大きさの範囲でいくつの画像サンプルを採るべきか、あるいは、バラツキのある複数の画像サンプルから、どの画像サンプルを学習に用いるべきかという検討である。


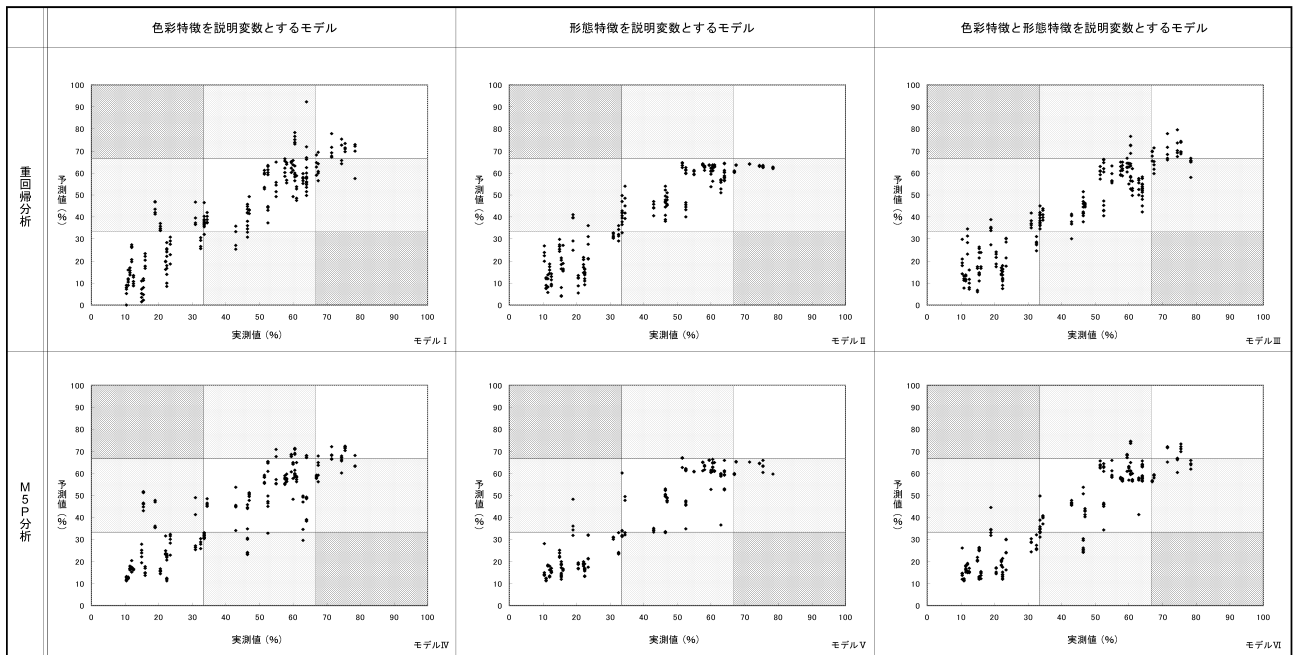
### 参考文献

- 1) 豊田宏, 坂部寛, 伊藤孝, 小西孝, 鳥居壮, 繊維補強膜材料の暴露条件と耐候性の関係について. 繊維学会誌, pp.484-488, 1994.
- 2) 山田守, 田中秀樹, CCD カメラと画像処理を用いた RC 構造物のひび割れ計測—その 4. 日本建築学会大会学術講演梗概, pp.537-538, 2004.
- 3) 西脇達哉, 三橋博三, ひび割れ画像解析を用いたコンクリートの劣化度評価に関する実験的研究. 日本建築学会大会学術講演梗概, pp.191-192, 2004.
- 4) 南宏和, 膜利用構造物の未来 飛行船・巨大ドームからあらゆる構造物へ. 日刊工業新聞社, 2004.

- 5) D. Aha, D. Kibler, Instance-based learning algorithms. In *Machine Learning*, pp.37–66, volume 6, 1991.
- 6) Ross Quinlan, C4.5: Programs for Machine Learning. In *Morgan Kaufmann Publishers*, 1993.
- 7) P. S. Bradley, U. M. Fayyad, Refining Initial Points for K-Means Clustering. In *Proceedings of the 15th International Conference on Machine Learning*, pp.91–99, 1998.
- 8) M. A. Hall, Correlation-based Feature Subset Selection for Machine Learning. , Ph.D Thesis, Univ.Waikato, 1999.
- 9) R. J. Quinlan, Learning with Continuous Classes. In *Proc. 5th Australian Joint Conference on Artificial Intelligence*, pp.343–348, 1992.

#### 謝辞

構築されたモデルの自動化システムの作成には、高橋宣行（京都大学大学院工学研究科建築学専攻 大学院生）氏に当たって頂いた。また、研究全体を通して画像分野の研究での経験を生かした貴重なアドバイスを頂戴し、様々な局面で協力をして頂いた。ここに感謝の意を表す。



劣化度ランクの同定結果

- 予測が実測と一致
- 予測が一つ上か下の実測ランクに一致
- 予測が2つ上か下の実測ランクに一致

右図の数値は同定結果の度数を表す

モデルⅠ

A	0	8	20
B	9	95	10
C	70	7	0
	C	B	A

モデルⅡ

A	0	0	0
B	6	109	30
C	79	1	0
	C	B	A

モデルⅢ

A	0	5	22
B	10	104	10
C	75	1	0
	C	B	A

モデルⅣ


A	0	16	12
B	17	76	18
C	68	18	0
	C	B	A

モデルⅤ

A	0	4	0
B	3	96	30
C	82	10	0
	C	B	A

モデルⅥ

A	0	11	10
B	3	88	20
C	82	11	0
	C	B	A



モデル A

A	0	5	22
B	10	104	10
C	75	1	0
	C	B	A

モデル B

A	0	1	4
B	2	21	2
C	15	0	0
	C	B	A

モデル C

A	0	0	2
B	1	21	4
C	16	1	0
	C	B	A

モデル D

A	0	11	10
B	3	88	20
C	82	11	0
	C	B	A

モデル E

A	0	2	2
B	1	19	4
C	16	1	0
	C	B	A

モデル F

A	0	1	1
B	0	17	5
C	17	4	0
	C	B	A

図 14 上：分析手法と用いる特徴による予測モデルの精度の違い 下：予測値の採り方による予測モデルの精度の違い

DEVELOPMENT OF AUTOMATIC DIAGNOSTIC SYSTEM  
FOR DETERIORATED MEMBRANE MATERIALS  
with Image Analysis and Image Recognition

Jun YANAGIMURO\*<sup>1</sup> Wonyong KOO\*<sup>1</sup> Atsushi TAKIZAWA\*<sup>2</sup> Naoki KATOH\*<sup>3</sup>  
Hiroshi TOYODA\*<sup>4</sup> Jun FUJIWARA\*<sup>4</sup> Kenshi ODA\*<sup>4</sup>

SYNOPSIS

Digital photographs taken with the microscope are used practically to diagnose deteriorated membrane materials. In this paper we present a new automated diagnostic system utilizing image analysis and image recognition instead of checking with human eyes. We first extract from a digital image statistics of color information and features of the objects that emerge along with deterioration such as cracks on the polyethylene resin coating and exposed fabrics. We then use these features as explanatory variables for building prediction models which are constructed based on multiple linear regression and a certain type of data mining method which combines multiple linear regression and decision tree. We have carried out comparison of prediction models through cross validation test. As the result of the experimental tests, our prediction model exhibited more than 90% accuracy in coefficient of correlation.

---

\*<sup>1</sup> Graduate Student, Dept. of Arch. and Architectural Eng., Kyoto Univ.

\*<sup>2</sup> Reserch Assoc., Dept. of Arch. and Architectural Eng., Kyoto Univ. Dr. Eng.

\*<sup>3</sup> Prof., Dept. of Arch. and Architectural Eng., Kyoto Univ. Dr. Eng.

\*<sup>4</sup> Research Engineer, Advanced R&D Department, Taiyo Kogyo Corporation, Dr. Eng.