

(19) 日本国特許庁(JP)

(12) 公開特許公報(A)

(11) 特許出願公開番号

特開2021-145557

(P2021-145557A)

(43) 公開日 令和3年9月27日(2021.9.27)

(51) Int.Cl.	F 1	テーマコード (参考)
AO1G 7/00 (2006.01)	AO1G 7/00 603	5L096
GO6T 7/00 (2017.01)	GO6T 7/00 350C	

審査請求 未請求 請求項の数 9 O L (全 18 頁)

(21) 出願番号	特願2020-45331 (P2020-45331)	(71) 出願人	397073201 株式会社電通国際情報サービス 東京都港区港南二丁目17番1号
(22) 出願日	令和2年3月16日 (2020.3.16)	(71) 出願人	000005278 株式会社ブリヂストン 東京都中央区京橋三丁目1番1号
		(74) 代理人	110002860 特許業務法人秀和特許事務所
		(72) 発明者	森田 浩史 東京都港区港南二丁目17番1号 株式会社電通国際情報サービス内
		(72) 発明者	藤木 隆司 東京都港区港南二丁目17番1号 株式会社電通国際情報サービス内

最終頁に続く

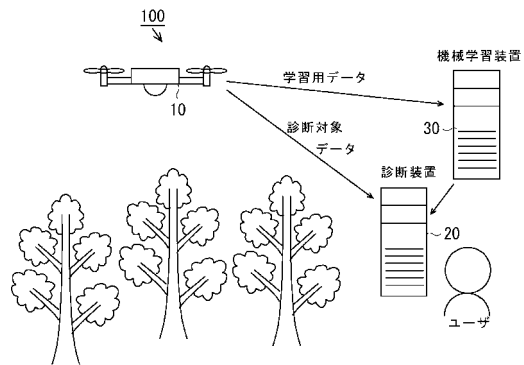
(54) 【発明の名称】 罹病木診断システム、罹病木診断方法、及び罹病木診断プログラム

(57) 【要約】

【課題】 樹木の罹病を高精度に診断可能にする技術を提供する。

【解決手段】 診断対象とする樹木の画像を取得する対象取得部と、樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして、樹木の画像から罹病している葉群を含む樹木を罹病木として診断するための機械学習を行った診断モデルに、前記診断対象とする樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断する診断部と、前記診断の結果を出力する診断結果出力部とを備える。

【選択図】 図1



【特許請求の範囲】**【請求項 1】**

診断対象とする樹木の画像を取得する対象取得部と、
樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして、樹木の画像から罹病している葉群を含む樹木を罹病木として診断するための機械学習を行った診断モデルに、前記診断対象とする樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断する診断部と、
前記診断の結果を出力する診断結果出力部と、
を備える罹病木診断システム。

10

【請求項 2】

前記樹木の画像が、前記樹木の上方から撮影した俯瞰画像である請求項 1 に記載の罹病木診断システム。

【請求項 3】

前記葉群が、前記樹木の上端より所定距離下側に設定された第一高さ、当該第一高さより所定距離下側に設定された第二高さとの間に存在するものである請求項 1 又は 2 に記載の罹病木診断システム。

【請求項 4】

前記診断モデルが、前記樹木の画像に対して、回転、移動、拡大、縮小、反転、色変化、ノイズ付加、ぼかし、高周波成分強調、及び歪みのうち少なくとも一つの画像処理を施し、画像処理後の画像を画像処理前の画像と別の教師データとすることで増加させた教師データを用いて機械学習を行ったものである請求項 1 ~ 3 の何れか 1 項に記載の罹病木診断システム。

20

【請求項 5】

前記診断対象の画像において前記罹病木と診断された樹木の当該画像内の位置に基づいて、前記罹病木が存在している位置を特定する位置特定部を更に備えた請求項 1 ~ 4 の何れか 1 項に記載の罹病木診断システム。

【請求項 6】

前記診断対象の画像が、前記樹木の上空を飛行する飛行体によって撮影された場合に、前記位置特定部が、前記診断対象の画像が撮影された時の前記飛行体の位置と、前記罹病木と診断された樹木の当該画像内の位置とに基づいて、前記罹病木が存在している位置を特定する請求項 5 に記載の罹病木診断システム。

30

【請求項 7】

診断対象とする樹木の画像を取得するステップと、
樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして、樹木の画像から罹病している葉群を含む樹木を罹病木として診断するための機械学習を行った診断モデルに、前記診断対象とする樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断するステップと、
前記診断の結果を出力するステップと、
をコンピュータが実行する罹病木診断方法。

40

【請求項 8】

診断対象とする樹木の画像を取得するステップと、
樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして、樹木の画像から罹病している葉群を含む樹木を罹病木として診断するための機械学習を行った診断モデルに、前記診断対象とする樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断するステップと、
前記診断の結果を出力するステップと、
をコンピュータに実行させるための罹病木診断プログラム。

50

【請求項 9】

樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして取得するデータ取得部と、

前記教師データを用いて機械学習することにより、樹木の画像から罹病している葉群を含む樹木を罹病木として診断する診断モデルを生成するモデル生成部と、
を備える機械学習装置。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、罹病木診断システム、罹病木診断、及び罹病木診断プログラムに関する。

10

【背景技術】

【0002】

従来、パラゴムノキの病気として、根白腐病が知られている。根白腐病は、病原菌が根に感染し組織を腐敗させることで、樹木を枯死させる。罹病した木を放置すると、周囲の健全な木に伝染するため、罹病を早期に発見して対処することが望ましい。この罹病の診断は、例えば、熟練者が葉の色や状態を見て見当をつけ、罹病が疑われる木の根を掘って、感染しているか否かを確定していた。

【0003】

また、特許文献1では、植物病の画像と対応する診断結果とを学習データとして複数取り込み、植物病に関する画像特徴データを作成し、保持する深層学習器と、診断対象とする画像を入力する入力部と、前記深層学習器を用いて、入力された画像がどの診断結果に分類されるかを識別する解析部とを備える植物病診断システムが提案されている。

20

【先行技術文献】

【特許文献】

【0004】

【特許文献1】特開2016-168046号公報

【非特許文献】

【0005】

【非特許文献1】論文SSD: Single Shot MultiBox Detector (2016) Wei Liu 他 <https://arxiv.org/pdf/1512.02325.pdf>

30

【発明の概要】

【発明が解決しようとする課題】

【0006】

早期に罹病を発見するためには、僅かな病変を見分ける必要があり、熟練者であっても診断が難しく、罹病か健全かを明確に診断できないケースもある。罹病の見落としを防ぐためには、明確に健全と判断できる樹木以外は、罹病木と診断することになる。このため、罹病と診断された木の根を掘り、根の状態を確認した際に、健全であること、即ち診断が誤っていたとの結果になる割合が多く、無駄に根を掘って確認する手間がかかるという問題があった。そこで、診断の精度、特に罹病と診断した場合の正確性（再現率）の向上が望まれていた。

40

【0007】

また、特許文献1では、植物病の画像と診断結果を取り込んで画像特徴データを作成し、入力画像がどの診断結果に該当するかを識別する。この場合、入力画像上で病変が明らかであれば、診断可能であるが、ゴムの木のように、主な病変が根に現れ、地上部の病変が僅かなものは、精度良く診断することができなかった。例えば、罹病したゴムの木の葉は黄色味が健全なものより強くなるが、若い健全な葉も同様の色であり、葉の色で診断することは困難である。同様に、葉の形状についても健全なものとは大きな差はなく、例えば、罹病木の葉を個々に撮影して画像特徴データを作成しても、罹病を精度良く診断することはできなかった。

【0008】

50

そこで、本発明は、樹木の罹病を高精度に診断可能にする技術の提供を目的とする。

【課題を解決するための手段】

【0009】

上記課題を解決するため、本発明の罹病木診断システムは、
診断対象とする樹木の画像を取得する対象取得部と、

樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして、樹木の画像から罹病している葉群を含む樹木を罹病木として診断するための機械学習を行った診断モデルに、前記診断対象とする樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断する診断部と、

10

前記診断の結果を出力する診断結果出力部と、を備える。

【0010】

前記樹木の画像は、前記樹木の上方から撮影した俯瞰画像であってもよい。

【0011】

前記罹病木診断システムは、前記葉群が、前記樹木の上端より所定距離下側に設定された第一高さ、当該第一高さより所定距離下側に設定された第二高さとの間に存在するものであってもよい。

【0012】

前記罹病木診断システムは、前記診断対象とする樹木の画像に対して、回転、移動、拡大、縮小、反転、色変化、ノイズ付加、ぼかし、高周波成分強調、及び歪みのうち少なくとも1つの画像処理を施し、画像処理後の画像を画像処理前の画像と別の教師データとし、前記教師データの数を増加させる前処理部を更に備え、

20

前記モデル作成部が、増加された教師データを用いて機械学習を行ってもよい。

【0013】

前記罹病木診断システムは、前記診断対象の画像において前記罹病木と診断された樹木の当該画像内の位置に基づいて、前記罹病木が存在している位置を特定する位置特定部を更に備えてもよい。

【0014】

前記診断対象の画像が、前記樹木の上空を飛行する飛行体によって撮影された場合に、前記位置特定部が、前記診断対象の画像が撮影された時の前記飛行体の位置と、前記罹病木と診断された樹木の当該画像内の位置とに基づいて、前記罹病木が存在している位置を特定してもよい。

30

【0015】

上記課題を解決するため、本発明の罹病木診断方法は、
診断対象とする樹木の画像を取得するステップと、

樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして、樹木の画像から罹病している葉群を含む樹木を罹病木として診断するための機械学習を行った診断モデルに、前記診断対象とする樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断するステップと、

40

前記診断の結果を出力するステップと、
をコンピュータが実行する。

【0016】

本発明は、前記罹病木診断方法の各ステップをコンピュータに実行させるための罹病木診断プログラムであってもよい。また、本発明は、前記罹病木診断プログラムをコンピュータが読み取り可能であって、非一時的に記憶する記憶媒体であってもよい。

【0017】

上記課題を解決するため本発明の機械学習装置は、

樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして取得するデータ取得部と、

50

前記教師データを用いて機械学習することにより、樹木の画像から罹病している葉群を含む樹木を罹病木として診断する診断モデルを生成するモデル生成部と、
を備える。

【発明の効果】

【0018】

本発明は、樹木の罹病を高精度に診断可能にする技術を提供することができる。

【図面の簡単な説明】

【0019】

【図1】実施形態に係る罹病木システムの概略構成図である。

【図2】飛行体の構成図である。

10

【図3】診断装置の構成図である。

【図4】診断装置のハードウェア構成図である。

【図5】機械学習装置の構成図である。

【図6】画像データを教師データとする処理の説明図である。

【図7】機械学習装置のハードウェア構成図である。

【図8】診断装置が、診断対象とする樹木の画像について、罹病木の診断を行う処理を示す図である。

【図9】ログデータの一例を示す図である。

【図10】画像内の位置に基づいて、前記罹病木が存在している位置を特定する処理の説明図である。

20

【図11】マップ上に罹病木の位置をプロットした例を示す図である。

【図12】SSDネットワーク構造を示す図である。

【図13】複数のデータセットの内訳を示す図である。

【図14】診断結果の一例を示す図である。

【発明を実施するための形態】

【0020】

第一実施形態

《装置構成》

以下本発明の一実施形態について図面を用いて説明する。図1は、本実施形態に係る罹病木診断システム100の概略構成図である。罹病木診断システム100は、飛行体10や、診断装置20、機械学習装置30を有している。罹病木診断システム100は、飛行体10によって上空から診断対象とする樹木の画像を撮影し、ディープラーニングによって作成した診断モデル(ニューラルネットワーク)を用いて、診断対象とする樹木の画像から罹病木を診断する。この診断モデルは、上方から撮影した樹木の俯瞰画像と、当該画像内で罹病の特徴を有する葉群が写っている範囲を示す情報とを教師データとしてディープラーニング(機械学習)を行ったものである。このように本実施形態の罹病木診断システム100は、上方から撮影した葉群の状態に基づいて診断を行うことにより、葉群に現れる罹病の特徴を的確に捉え、高精度に罹病木の診断を行うことができるようにしている。

30

【0021】

本実施形態では、パラゴムノキの病害診断の例を説明する。パラゴムノキの根白腐病は、糸状菌の一種であるパラゴムノキ根白腐病菌(Rigidoporus microporus, ネットイヌメタケ)が根に感染することで引き起こされる病害である。病害が進行すると、根が腐敗し、樹木が枯死する。また、病害が進行する過程で、病原菌が周囲の健全な木の根にも感染して罹病させるので、罹病を早期に発見して対処することが望ましい。しかしながら、罹病初期の病変は、主に地下の根で起こり、地上部の変化は僅かである。例えば、根が水分を十分に吸収できなくなることで葉が黄変する。しかしながら、この黄変は僅かで、若い葉や日当たりの少ない葉も同様の色を呈することがあるため、葉の色だけから病害を診断することはできなかった。そこで本実施形態の罹病木診断システム100は、葉群の画像に基づいて罹病を診断する。これにより、葉の色だけでなく、葉の付き方、特に葉の密

40

50

集度や、枝に対する葉の角度などに基づき、精度良く診断できる。また、樹木の上方から撮影した画像を用いることにより、この画像に写る葉は、上空から見通せる位置にあるものとなり、日当たりが悪いことによって黄変したものを除外できるので、精度良く診断できる。

【 0 0 2 2 】

《 飛行体 》

図 2 は、飛行体 1 0 の構成図である。図 2 に示すように、飛行体 1 0 は、駆動部 1 1 や、制御部 1 2、撮影装置 1 3、位置情報取得部 1 4 を備えた小型無人機（ドローン）である。

【 0 0 2 3 】

駆動部 1 1 は、モータ又は内燃機関によってプロペラを回転させることによって浮力を得ると共に、プロペラの回転軸を垂直軸に対して傾けることによって推力を得る。駆動部の構成はこれに限らず、他の構成であってもよい。例えば、浮力を得るための気球と推力を得るためのプロペラとを有する構成であってもよい。

【 0 0 2 4 】

制御部 1 2 は、ユーザによる操作を受け付けて、当該操作に応じて駆動部 1 1 を制御し、飛行体 1 0 の飛行状態を制御する。また、制御部 1 2 は、撮影装置 1 3 を制御し、撮影の開始や停止、撮影方向の変更などの動作を制御する。

【 0 0 2 5 】

撮影装置 1 3 は、撮影レンズ 1 3 A により、診断対象としての樹木の像を撮像素子 1 3 B の受光面上に形成し、当該像を撮像素子 1 3 B によって電気信号に変換して撮影画像のデータを取得する。また、本実施形態の撮影装置 1 3 は、撮影画像のデータをその撮影時刻と共に記録する。

【 0 0 2 6 】

位置情報取得部 1 4 は、衛星測位システム等によって位置情報を取得し、撮影装置 1 3 で撮影を行った際の自己の位置（撮影位置とも称す）を撮影画像と対応つけて記録する。例えば、位置情報（緯度・経度など）を所定周期で取得し、その取得時刻と共にログデータとして記録する。これにより、撮影画像の撮影時刻とログデータを照合することで、撮影時に飛行体 1 0 が何処に位置していたかが求められる。また、ログデータは、位置情報と共に、飛行体 1 0 が、どの方角に向いているのかを示す姿勢情報を記録してもよい。

【 0 0 2 7 】

なお、飛行体 1 0 は、小型無人機に限らず、有人の飛行機やヘリコプター、人工衛星等であってもよい。

【 0 0 2 8 】

《 診断装置 》

図 3 は、診断装置 2 0 の構成図である。図 3 に示すように、診断装置 2 0 は、対象取得部 2 1 や、診断部 2 2、診断結果出力部 2 3、位置特定部 2 4 を有している。

【 0 0 2 9 】

対象取得部 2 1 は、診断対象とする樹木の画像データを飛行体 1 0 から取得する。この画像データの取得は、例えば、通信ケーブル又は通信ネットワークを介して飛行体 1 0 と接続し、通信によって飛行体 1 0 から受信する。また、飛行体 1 0 が、診断対象とする樹木の画像データをメモリカード等の記憶媒体に記憶し、診断装置 2 0 が、この記憶媒体から当該画像データを読み出して取得してもよい。

【 0 0 3 0 】

診断部 2 2 は、樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして、樹木の画像から罹病している葉群を含む樹木を罹病木として診断するための機械学習を行った診断モデルに、前記診断対象とする樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断する。

【 0 0 3 1 】

10

20

30

40

50

診断結果出力部 2 3 は、診断部 2 2 による診断の結果を出力する。この診断の結果の出力は、例えば、表示装置への表示、プリンタによる印刷、記憶媒体への記憶、他の装置への送信等である。

【 0 0 3 2 】

位置特定部 2 4 は、前記診断対象の画像において前記罹病木と診断された樹木の当該画像内の位置に基づいて、前記罹病木が存在している位置を特定する。例えば、前記診断対象の画像が、前記樹木の上空を飛行する飛行体によって撮影された場合に、前記位置特定部が、前記診断対象の画像が撮影された時の前記飛行体の位置と、前記罹病木と診断された樹木の当該画像内の位置とに基づいて、前記罹病木が存在している位置を特定する。

【 0 0 3 3 】

図 4 は、診断装置 2 0 のハードウェア構成図である。診断装置 2 0 は、接続バス 2 2 1 によって相互に接続されたプロセッサ 2 2 2、メモリ 2 2 3、入出力 I F (インターフェース) 2 2 4、通信 I F 2 2 5 を有するコンピュータである。プロセッサ 2 2 2 は、入力された情報を処理し、処理結果を出力することにより、装置全体の制御等を行う。プロセッサ 2 2 2 は、C P U (Central Processing Unit) や、M P U (Micro-processing unit) とも呼ばれる。プロセッサ 2 2 2 は、単一のプロセッサに限られず、マルチプロセッサ構成であってもよい。また、単一のソケットで接続される単一のチップ内に複数のコアを有したマルチコア構成であってもよい。

【 0 0 3 4 】

メモリ 2 2 3 は、主記憶装置と補助記憶装置とを含む。主記憶装置は、プロセッサ 2 2 2 の作業領域、プロセッサ 2 2 2 で処理される情報を一時的に記憶する記憶領域、通信データのバッファ領域として使用される。主記憶装置は、プロセッサ 2 2 2 がプログラムやデータをキャッシュしたり、作業領域を展開したりするための記憶媒体である。主記憶装置は、例えば、R A M (Random Access Memory) や R O M (Read Only Memory)、フラッシュメモリを含む。補助記憶装置は、プロセッサ 2 2 2 により実行されるプログラムや、情報処理に用いられるデータ、動作の設定情報などを記憶する記憶媒体である。補助記憶装置は、例えば、H D D (Hard-disk Drive) や S S D (Solid State Drive)、E P R O M (Erasable Programmable ROM)、フラッシュメモリ、U S B メモリ、メモリカード等である。また、補助記憶装置は、対象取得部 2 1 で受信した診断対象とする樹木の画像 (撮影画像) や、診断結果を記憶する

【 0 0 3 5 】

入出力 I F 2 2 4 は、診断装置 2 0 に接続する機器との間でデータの入出力を行うインターフェースである。入出力 I F 2 2 4 は、例えば、C D や D V D 等の記憶媒体からデータを読み取るディスクドライブ、操作部、表示装置等の機器との間でデータの入出力を行う。操作部は、マウスやキーボード、タッチパネル等、オペレータの操作によって診断装置 2 0 に対する情報が入力される入力部である。表示装置は、処理結果などの情報をオペレータに対して表示出力する出力部である。

【 0 0 3 6 】

通信 I F 2 5 は、通信回線 N を介して他の装置との通信を行うインターフェース (通信モジュール) であり、C C U (Communication Control Unit) とも称す。なお、図 6 に示した診断装置 2 0 の構成要素はそれぞれ複数設けられてもよいし、一部の構成要素を設けないようにしてもよい。

【 0 0 3 7 】

本実施形態の診断装置 2 0 では、プロセッサ 2 2 2 が、アプリケーションプログラムを実行することにより、診断装置 2 0 は、対象取得部 2 1 や、診断部 2 2、診断結果出力部 2 3、位置特定部 2 4 といった各処理部として機能する。即ち、プロセッサ 2 2 2 は、実行するソフトウェアに応じて各処理部として兼用され得る。但し、上記各処理部の一部又は全部が、D S P (Digital Signal Processor)、A S I C (Application Specific Integrated Circuit)、F P G A (Field-Programmable Gate Array) 等の専用 L S I (large scale integration)、論理回路、その他のデジタル回路といったハードウェアで形成

10

20

30

40

50

されたものであってもよい。また、上記各処理部の少なくとも一部にアナログ回路を含む構成としてもよい。

【0038】

《機械学習装置》

図5は、機械学習装置30の構成図である。図5に示すように、機械学習装置30は、データ取得部31や、モデル生成部32を有している。

【0039】

データ取得部31は、樹木の画像、当該画像内で葉群が写っている範囲を示す情報、及び前記範囲内に罹病の特徴を有するか否かを示す情報を教師データとして取得する。

【0040】

モデル生成部32は、前記教師データを用いて機械学習することにより、樹木の画像から罹病している葉群を含む樹木を罹病木として診断する診断モデルを生成する。

【0041】

図6は、画像データを教師データとする処理の説明図である。図6において、画像41は、飛行体10によって撮影したオリジナル画像である。この画像41から、一本の木が写っている領域を木領域42として抽出する。本実施形態では、この木領域42を800×800ピクセル～1500×1500ピクセルで切り出している。

【0042】

次に、アノテーションツールを用い、これらの木領域42内の葉群が写っている範囲43を指定し、この範囲43内に罹病の特徴を有するか否かを入力し、これら範囲43を示す情報及び罹病か否かの情報をxml形式で記述したメタデータ44を作成する。そして、木領域42のデータとメタデータ44を教師データとして学習に用いる。ここで葉群とは、複数の葉の集まりであって、例えば5～500枚の葉を含むものである。なお、葉群を成す葉の数は、樹木の大きさ（幹の直径、樹高等）や種類、樹齢、目標とする検出精度等によって適宜定めてよく、10～300枚や、10～50枚であってもよい。葉群は、葉を支える枝を含んでもよい。また、一つの葉群は、同じ枝から派生した葉の集合や、枝の先端から所定距離内にある葉の集合であってもよい。ここで所定距離とは、例えば、50cm、1m、2mなど、30cm～3mの値である。このように、本実施形態では、葉単体の画像を教師データとするのではなく、葉群の画像（木領域42のデータ）を教師データとする。このため、本実施形態の教師データは、葉の色に加え、複数の葉の形状や、各葉の間隔（葉の密度）、枝に対する葉の角度（葉の付き方）等の情報を含む。例えば、若い葉であれば、柔らかく、枝から離れるにつれて、しな垂れるので、葉の付き方が、若い葉か否かの情報となる。このため、当該教師データを用いて学習した診断モデルであれば、黄色味が強い葉群について、葉がしな垂れていれば、若い葉のため健全と判別し、葉がしな垂れていなければ黄変の可能性が高いと判別できる。また、罹病して根が吸収する水分が減ることによって葉が縮れた場合、健全な場合と比べて、隣接する葉との間隔が広くなり、葉群の画像において葉の占める割合（葉の密度）が低くなる。このため、当該教師データを用いて学習した診断モデルは、罹病を診断する情報の一つとして、葉群の画像における葉の密度を用いることができる。

【0043】

このように、本実施形態では、樹木の画像について学習を行うが、学習に用いるデータは樹木の画像のみに限られるものではない。例えば犬、猫などの一般物体の画像セットを用いて事前学習し、事前学習済みのモデルをベースに、樹木の画像を用いて本番の学習（転移学習）を行って診断モデルを作成してもよい。これにより樹木の画像の数が少なくても高い検出精度の診断モデルを生成でき、教師データを作成する負荷を抑えることができる。

【0044】

また、アノテーションツールを用いて、木領域42内の葉群が写っている範囲43を指定する際、樹木の上端より所定距離下側に設定された第一高さ、当該第一高さより所定距離下側に設定された第二高さとの間に存在する葉群を指定してもよい。例えば、第一高

10

20

30

40

50

さは、樹木の上端より、50cm、1m、3mなど、50cm～5mの距離に設定される。また、第二高さは、第一高さより、1m、3m、5mなど、50cm～10mの距離に設定される。また、第一高さは、樹木の上端より、樹高の4%、6%、20%など、樹高の4%～30%にあたる距離に設定されてもよい。また、第二高さは、第一高さより、樹高の6%、20%、30%など、樹高の6%～50%にあたる距離に設定されてもよい。なお、第一高さ及び第二高さは、対象とする樹木の高さ(樹高)に応じて設定してもよい。本実施形態では、対象とする樹木がパラゴムノキであるため、この場合の樹高は、例えば10m～20mである。これに限らず、対象の樹木は、5m以上の高木としてもよい。

【0045】

更に、診断対象とする樹木の画像に対して、回転、移動、拡大、縮小、反転、色変化、ノイズ付加、ぼかし、高周波成分強調、及び歪みのうち少なくとも1つの画像処理を施し、画像処理後の画像を画像処理前の画像と別の教師データとし、教師データの数を増加させてもよい。これにより、明るさや画像の向き等の影響を抑えて高い検出精度の診断モデルを生成できる。

10

【0046】

図7は、機械学習装置30のハードウェア構成図である。機械学習装置30は、接続バス321によって相互に接続されたプロセッサ322、メモリ323、入出力IF(インターフェース)324、通信IF325を有するコンピュータである。プロセッサ322は、入力された情報を処理し、処理結果を出力することにより、装置全体の制御等を行う。プロセッサ322は、CPU(Central Processing Unit)や、MPU(Micro-processing unit)とも呼ばれる。プロセッサ322は、単一のプロセッサに限られず、マルチプロセッサ構成であってもよい。また、単一のソケットで接続される単一のチップ内に複数のコアを有したマルチコア構成であってもよい。

20

【0047】

メモリ323は、主記憶装置と補助記憶装置とを含む。主記憶装置は、プロセッサ322の作業領域、プロセッサ322で処理される情報を一時的に記憶する記憶領域、通信データのバッファ領域として使用される。主記憶装置は、プロセッサ322がプログラムやデータをキャッシュしたり、作業領域を展開したりするための記憶媒体である。主記憶装置は、例えば、RAM(Random Access Memory)やROM(Read Only Memory)、フラッシュメモリを含む。補助記憶装置は、プロセッサ322により実行されるプログラムや、情報処理に用いられるデータ、動作の設定情報などを記憶する記憶媒体である。補助記憶装置は、例えば、HDD(Hard-disk Drive)やSSD(Solid State Drive)、EPROM(Erasable Programmable ROM)、フラッシュメモリ、USBメモリ、メモリカード等である。

30

【0048】

入出力IF324は、機械学習装置30に接続する機器との間でデータの入出力を行うインターフェースである。入出力IF324は、例えば、CDやDVD等の記憶媒体からデータを読み取るディスクドライブ、操作部、表示装置等の機器との間でデータの入出力を行う。操作部は、マウスやキーボード、タッチパネル等、オペレータの操作によって機械学習装置30に対する情報が入力される入力部である。表示装置は、処理結果などの情報をオペレータに対して表示出力する出力部である。

40

【0049】

通信IF35は、通信回線Nを介して他の装置との通信を行うインターフェース(通信モジュール)であり、CCU(Communication Control Unit)とも称す。なお、図7に示した機械学習装置30の構成要素はそれぞれ複数設けられてもよいし、一部の構成要素を設けないようにしてもよい。

【0050】

本実施形態の機械学習装置30では、プロセッサ322が、アプリケーションプログラムを実行することにより、機械学習装置30は、データ取得部31や、モデル生成部32といった各処理部として機能する。即ち、プロセッサ322は、実行するソフトウェアに

50

応じて各処理部として兼用され得る。但し、上記各処理部の一部又は全部が、DSP (Digital Signal Processor)、ASIC (Application Specific Integrated Circuit)、FPGA (Field-Programmable Gate Array) 等の専用LSI (large scale integration)、論理回路、その他のデジタル回路といったハードウェアで形成されたものであってもよい。また、上記各処理部の少なくとも一部にアナログ回路を含む構成としてもよい。

【0051】

《診断方法》

図8は、診断装置20が、診断対象とする樹木の画像について、罹病木の診断を行う処理を示す図である。診断装置20は、診断の開始が指示された場合に図8の処理を実行する。

10

【0052】

ステップS10にて、診断装置20は、診断対象とする樹木の画像を取得する。

【0053】

ステップS20にて、診断装置20は、機械学習装置30によって生成された診断モデルに、ステップS10で取得した樹木の画像を入力することにより、罹病している葉群を含む樹木を罹病木として診断し、罹病している葉群を含まない樹木を健全木として診断する。

【0054】

ステップS30にて、診断装置20は、診断対象の画像において罹病木と診断された樹木の当該画像内の位置に基づいて、前記罹病木が存在している位置を特定する。例えば、診断装置20は、ログデータを参照し、診断対象の画像が撮影された時の前記飛行体10の位置及び姿勢、並びに罹病木と診断された樹木の当該画像内の位置とに基づいて、前記罹病木が存在している位置を特定する。

20

【0055】

図9は、ログデータの一例を示す図、図10は画像内の位置に基づいて、前記罹病木が存在している位置を特定する処理の説明図である。

【0056】

飛行体10は、図9に示すように、飛行体10の位置情報45と、当該位置情報を取得した時刻を示す時刻情報46と、当該時刻における飛行体10の姿勢情報47とを有している。位置情報45は、例えば、世界測地系における経緯度(経度・緯度)および標高を用いて位置を示す情報である。姿勢情報47は、例えば、飛行体10が水平で所定の方向(例えば北)を向いた状態を基準とし、この基準状態からの傾きをピッチ方向、ロール方向、及びヨー方向の回転角度で示した値である。

30

【0057】

図10に示す画像51は、撮影装置13で撮影されたものであり、例えば画像51の中心を原点52とし、この原点52を通るX軸が飛行体10の前後軸に相当し、Y軸が飛行体10の左右軸に相当する。飛行体10が、撮影レンズを真下に向けて配置し、飛行体10が水平状態で飛行した場合、画像51の中心に写る物体は、飛行体10と同じ緯度・経度に存在するものである。

【0058】

また、図10において物体53は、画像51において、原点52からX軸方向に距離 L_x だけ離れ、Y軸方向に距離 L_y だけ離れた位置に写っている。樹木が存在する地上面において、画像51上の距離 L_x 、 L_y に相当する距離は、例えば撮影レンズの画角や飛行体10の標高(地上から飛行体までの高さ)によって求められる。そして、飛行体10の位置から、X軸に相当する方向へ距離 L_x に相当する距離だけ離れ、X軸に相当する方向へ距離 L_x に相当する距離だけ離れた位置を物体53が存在する位置として求めることができる。なお、飛行体10の姿勢が、基準状態から傾いている場合には、この傾きに応じて画像上の位置と地上の位置との位置関係が変わるので、姿勢情報47に応じて、画面上の位置に対応する地上での位置を求める。

40

【0059】

50

ステップS40にて、診断装置20は、ステップS30で求めた罹病木の位置などを診断の結果として出力する。図11は、マップ上に罹病木の位置をプロットした例を示す図である。なお、図11において、白抜きの「D」「M」「L」が罹病木を示している。なお、「D」は重度、「M」は中程度、「L」は軽度の罹病木である。

【0060】

《Single Shot MultiBox Detector》

本実施形態の診断部22は、撮影画像から罹病の特徴を検出する手法として、Wei Liuらの論文であるSSD: Single Shot MultiBox Detector (2016)で提案されている手法を採用した。図12は、SSDネットワーク構造を示す図である。この手法は、フィードフォワード畳み込みネットワークに基づいており、固定長サイズのバウンディングボックスの集まり(collection)を生成し、物体クラスの実体がそれらのボックスの中に存在することをスコア付けし、そして最終的な検出を生成するためにnon-maximum suppression (NMS、例えば近隣ピクセルと注目しているピクセルの値を比較し、注目しているピクセルが最大値でないときは0にする処理)を行う。

10

【0061】

ネットワークの最初の方のレイヤは画像分類に使用される標準的なアーキテクチャに基づいており、これをベースネットワークとする。ベースネットワークにはVGG-16ネットワークを使用した、これに限定されるものではない。

【0062】

畳み込み特徴レイヤをベースネットワークの最後尾に追加した。これらのレイヤはサイズを大きく減少させ、マルチスケールでの検出の予測を可能にする。検出を予測するための畳み込みモデルは各特徴レイヤに関して異なっている。

20

【0063】

追加された各特徴レイヤ(またはベースネットワークの既存の特徴レイヤとしてもよい)は畳み込みフィルタのセットを使って固定の検出予測のセットを生成可能である。これらは図12のSSDネットワーク構造のトップに示されている。pチャンネルを持つサイズ $m \times n$ の特徴レイヤに対して、潜在的な検出パラメタ予測のための基本要素は $3 \times 3 \times p$ の小さなカーネルであり、それはカテゴリのスコア、またはデフォルトボックスの座標に対しての形状オフセットを生成する。カーネルは、それが適用される $m \times n$ の各位置において出力値を生成する。バウンディングボックスオフセットの出力値は、各フィーチャマップの位置に対するデフォルトボックスの位置に対して測定される。

30

【0064】

この例では、ネットワークのトップで、複数フィーチャマップについて各フィーチャマップのセルとデフォルトバウンディングボックスのセットを関連付けている。その対応するセルに対して各デフォルトボックスの位置が固定されるように、デフォルトボックスは畳み込みのやり方でフィーチャマップを隙間なく敷き詰めている。各フィーチャマップのセルにおいて、クラスのインスタンスがそれらの各ボックス中に存在することを示すクラスごとのスコアと同様に、セル中のデフォルトボックスの形状に対するオフセットを予測する。具体的には、ある位置で k 個のボックスそれぞれについて、 c 個のクラススコアと元のデフォルトボックスの形状に対するオフセット4つを計算する。この結果、フィーチャマップの各位置の周辺に適用されるフィルタは合計 $(c+4)k$ 個となり、 $m \times n$ のフィーチャマップに関して $(c+4)kmn$ 個の出力を生成する。本例のデフォルトボックスは、解像度の異なるいくつかのフィーチャマップに適用する。いくつかのフィーチャマップで異なるデフォルトボックスの形状を使用することは、出力されるボックスの形状を効率よく離散化できる。また、本例では、デフォルトボックスをjaccard overlapが閾値(0.5)よりも高い正解ボックス全てとマッチさせる。これにより1つのデフォルトボックスだけを選択させる方法よりも学習問題をシンプルにしている。

40

【0065】

本例のSSDの訓練において、 $x^p_{ij} = \{1, 0\}$ はカテゴリ p での i 番目のデフォルトボックスと j 番目の正解ボックスのマッチングを示すものとする。上記のマッチング戦略にお

50

いて、 $\sum_{i,j} x_{ij}^p - 1$ を得ることができる。この場合、図12の式Aのように全体の目的誤差関数（損失関数）は、位置ずれ誤差(loc)と分類誤差(conf)の重み付き和である。

【0066】

ここでNはマッチしたデフォルトボックスの数である。N=0の場合は誤差を0とする。位置ずれ誤差は予測されたボックス(l)と正解ボックス(g)のパラメタ間でのSmooth L1誤差である(式B)。そして、デフォルトバウンディングボックス(d)の中心(cx, xy)と、その幅(w)と高さ(h)についてオフセットを回帰する。分類誤差は複数クラスの確信度(c)に対するソフトマックス誤差である(式C)。次の評価ではクロスバリデーションにより、重み項は1にセットした。

【0067】

《診断結果の評価》

クローンや樹齢の差による診断結果への影響を確認するため、複数のデータセットで評価を行った。図13は、複数のデータセットの内訳を示す図である。図13の例では、クローンP2~P3、樹齢若年~老年の樹木のデータを用いた。このうち、データセット(i)では、クローンP2、樹齢壮年としたブロック単体のデータを用い、データセット(ii)では、クローンP3、樹齢若年~老年とした異なる樹齢のデータを用いた。また、データセット(iii)では、クローンP2~P4、樹齢壮年とした異なるクローンのデータを用いた。そして、データセット(iv)では、データ全体を用い、データセット(v)では、重篤な罹病木のデータを用いた。

【0068】

図14は、診断結果の一例を示す図である。図14において、H1~H6, D1~D6は、診断部22によって撮影画像から抽出された木領域である。木領域H1~H6, D1~D6において、矩形状の枠とラベルを付された箇所が診断部22によって選択された葉群の画像である。なお、本実施形態の診断部22は、選択した葉群のうち、罹病の特徴を有するもの(以下、罹病葉群とも称す)の枠及びラベルを赤色にして示したが、図14では、この罹病葉群のラベルに斜線の網掛けを付して示している。また、診断部22は、選択した葉群のうち、罹病の特徴を有しない健全なもの(以下、健全葉群とも称す)の枠及びラベルを青色にして示したが、図14では、この健全葉群のラベルを白塗りにして示している。図14の例において、診断部22は、罹病葉群を有する木領域H05, D1, D2, D4~D6に写る樹木を罹病木と診断し、罹病葉群を有しない木領域H01~H4, H6, D3に写る樹木を健全木と診断する。

【0069】

この診断結果を評価するために、診断対象とした樹木の根を掘るなどして実際に確認したところ、木領域H1~H6の樹木は健全木、木領域D1~D6の樹木は罹病木であった。即ち、木領域H5は、健全木を罹病木と間違え、木領域D3は罹病木を健全木と間違え、その他は正解している。

【0070】

このように診断部22により「罹病」又は「健全」と診断した結果についてそれぞれ、実際に「罹病」か「健全」かを確認した結果を表1のように分類し、これらを用いて正解率(Accuracy)、適合率(Precision)、再現率(Recall)を求め、評価を行った。

【表1】

		確認結果	
		罹病	健全
診断結果	罹病	TP	FP
	健全	FN	TN

【0071】

ここで、TPは、診断部22の診断結果が罹病であり、その確認結果が罹病であった場合である。FPは、診断部22の診断結果が罹病であり、その確認結果が健全であった場

10

20

30

40

50

合である。FNは、診断部22の診断結果が健全であり、その確認結果が罹病であった場合である。TNは、診断部22の診断結果が健全であり、その確認結果が健全であった場合である。

【0072】

正解率は、診断部22が「健全」又は「罹病」とした診断結果と、実際の確認結果とが一致する割合であり、次の式1から求められる。

$$\text{正解率} = (TP + TN) / (TP + FP + TN + FN) \cdots \text{式1}$$

【0073】

適合率は、診断部22が「罹病」とした診断結果が、実際に「罹病」である割合であり、次の式2から求められる。

$$\text{適合率} = TP / (TP + FP) \cdots \text{式2}$$

【0074】

再現率は、実際に「罹病」であるものが、診断部22で「罹病」と診断される割合であり、次の式3から求められる。

$$\text{再現率} = TP / (TP + FN) \cdots \text{式3}$$

【0075】

【表2】

	accuracy [%]	precision [%]	recall [%]
(i)ブロック単体	78	83	83
(ii)異なる樹齡	57	78	42
(iii)異なるクローン	64	63	81
(iv)データ全体	59	61	73
(v)罹病重のみ	71	70	91

【0076】

表2は、診断部22の診断結果について、実際の確認結果と比較して、正解率(Accuracy)、適合率(Precision)、再現率(Recall)を評価した結果を示している。

【0077】

表2に示すように、樹齡の異なるデータセット(ii)では、正解率及び再現率が低いという結果となった。これは、樹齡が異なることで、画像上の形態が異なるためと推定される。このため異なる樹齡のデータが含まれるデータセット(iv)についても同様に正解率の低下を招いていると推察される。

【0078】

なお、罹病の程度が重いデータセット(v)については、比較的精度が高く、特に再現率が高い結果となった。これは、罹病の程度が重い樹木の場合、罹病の特徴が、画像上に明確に表れるためと推察される。但し、罹病の早期発見を目指しているため、罹病の程度が軽い樹木についても、このように高い精度を得られることが望まれる。

【0079】

適切に管理されたゴムノキ農園の場合、罹病率は1%程度であるので、仮に、全ての樹木を健全と判断すれば、正解率が99%となるが、この場合、全ての罹病木を見逃すことになるので、正解率だけを高めても意味がない。反対に全ての樹木を罹病と診断すれば、再現率は100%となり、罹病木の見逃しは無くなるが、正解率及び適合率が1%と低くなり、当然診断する意味がない。特に適合率が低いと、罹病と診断された樹木について、治療や伐根等の対処を行う際、根元を掘り起こしたところで、実際には健全であることが確認され、掘り起こす等の作業が無駄になることが多くなる。このため、適合率と再現率とをそれぞれ適切に高められることが望ましい。

【0080】

本願の発明者達は、診断部22の診断精度を改善するにあたり、図12に示したSSD

10

20

30

40

50

のパラメタを変更して診断結果を求める等の検討を繰り返し、損失関数 $L(x, c, l, g)$ に着目した。この損失関数において、項 l は、分類誤差と位置ずれ誤差の比重を変更するパラメタであり、表 2 の診断では、 $l = 1$ としていた。発明者達は、鋭意検討の結果、本実施形態のように、上空から複数の樹木を撮影し、葉群の特徴を検出するという条件では、この損失関数 $L(x, c, l, g)$ のパラメタ l を小さくし、位置ずれ誤差に対する分類誤差の比重を高めることにより、診断精度を向上させられることを見出した。

【0081】

表 3 は、パラメタ l を 0.5 とした場合の診断結果を評価したものである。

【表 3】

	accuracy [%]	precision [%]	recall [%]
(i) ブロック単体	73	73	76
(ii) 異なる樹齢	63	71	60
(iii) 異なるクローン	65	64	83
(iv) データ全体	65	62	88
(v) 罹病重のみ	—	—	—

10

【0082】

表 3 に示すように、 $l = 0.5$ とすることで、全体的に精度が改善し、特にデータ全体 (iv) の再現性が向上し、88% を達成することができた。なお、パラメタ l は、0.5 に限定されるものではなく、例えば、0.25 ~ 0.75 の範囲としてもよい。

20

【0083】

上述のように、本実施形態によれば、高精度に罹病木の診断を行うことができる。従来、熟練者がパラゴムノキの地上部を目視して診断を行った場合には、20% 以下の精度であったため、本実施形態の診断装置によって、診断精度が大きく向上する。なお、本実施形態では、パラゴムノキの病害について説明したが、本実施形態の罹病木診断システムは、パラゴムノキに限定されるものではなく、葉群に罹病の特徴のある病害であれば、他の病害についても診断できる。

【0084】

なお、上記の実施形態や変形例は、一例であり、上記構成に限定されるものではなく、発明の趣旨に反しない範囲で変更してもよい。例えば上記の実施形態や変形例の要素を組み合わせたか、一部の要素を省略したりしてもよい。

30

【符号の説明】

【0085】

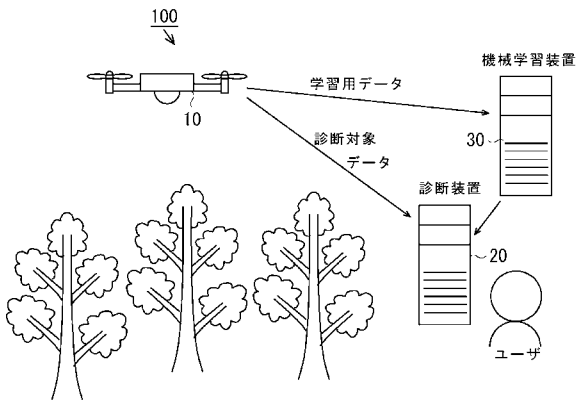
- 10 : 飛行体
- 11 : 駆動部
- 12 : 制御部
- 13 : 撮影装置
- 13A : 撮影レンズ
- 13B : 撮像素子
- 14 : 位置情報取得部
- 20 : 診断装置
- 21 : 対象取得部
- 22 : 診断部
- 23 : 診断結果出力部
- 24 : 位置特定部
- 30 : 機械学習装置
- 31 : データ取得部
- 32 : モデル生成部

40

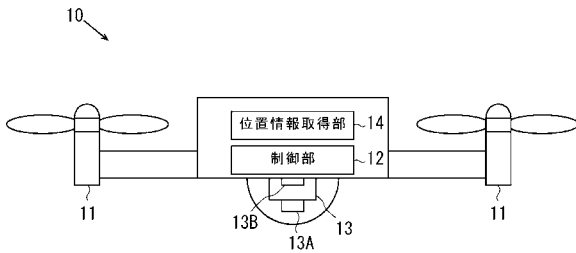
50

100 : 罹病木診断システム

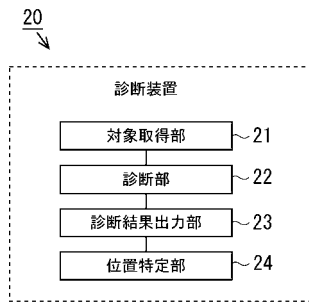
【図1】



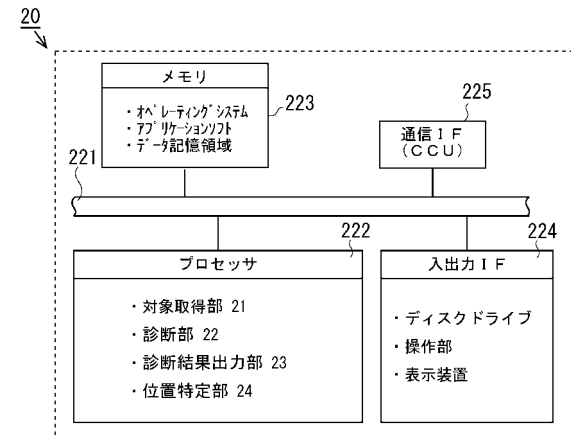
【図2】



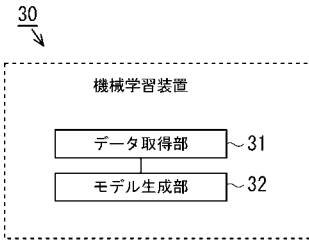
【図3】



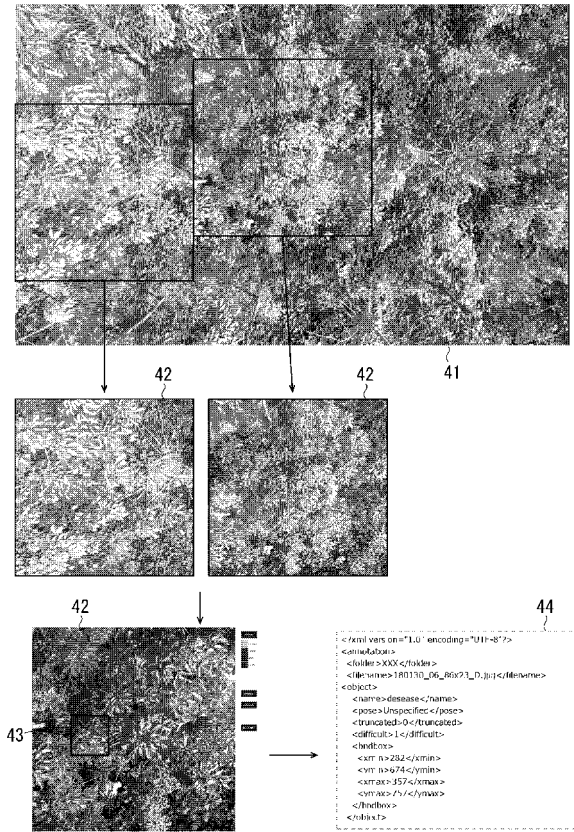
【図4】



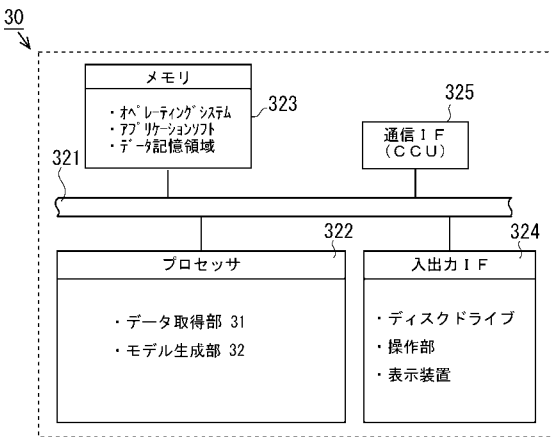
【図 5】



【図 6】



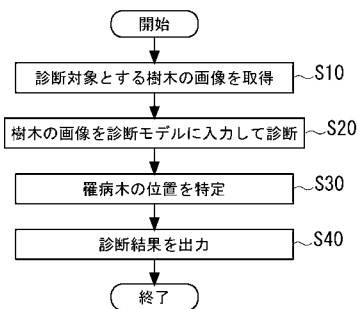
【図 7】



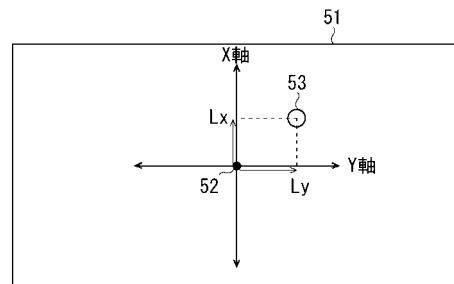
【図 9】

時刻	位置情報 (緯度、経度、標高)	姿勢情報 (ヨー、ピッチ、ロール)
00:00:00	(000,000,000)	(000,000,000)
00:00:00	(000,000,000)	(000,000,000)
00:00:00	(000,000,000)	(000,000,000)
00:00:00	(000,000,000)	(000,000,000)
⋮	⋮	⋮

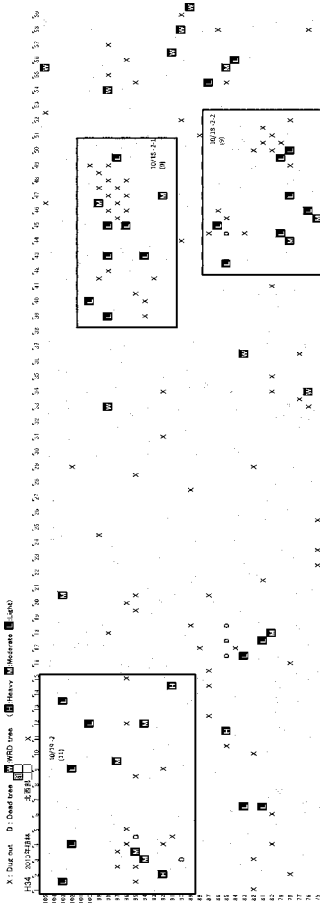
【図 8】



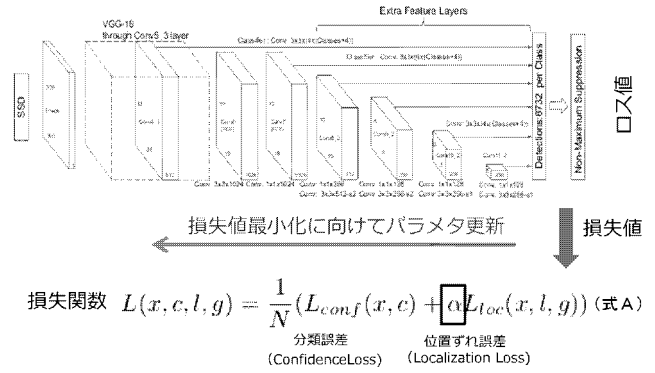
【図 10】



【図 1 1】



【図 1 2】



損失関数 $L(x, c, l, g) = \frac{1}{N} (L_{conf}(x, c) + \alpha L_{loc}(x, l, g))$ (式A)

分類誤差 (ConfidenceLoss) 位置ずれ誤差 (Localization Loss)

$$L_{loc}(x, l, g) = \sum_{i \in Pos} \sum_{m \in \{c, x, y, w, h\}} x_{ij}^k \text{smooth}_{r,1}(l_i^m - \hat{g}_j^m)$$

$$\hat{g}_j^x = (g_j^x - d_i^x) / d_i^w \quad \hat{g}_j^y = (g_j^y - d_i^y) / d_i^h$$

$$\hat{g}_j^w = \log\left(\frac{g_j^w}{d_i^w}\right) \quad \hat{g}_j^h = \log\left(\frac{g_j^h}{d_i^h}\right) \quad (\text{式B})$$

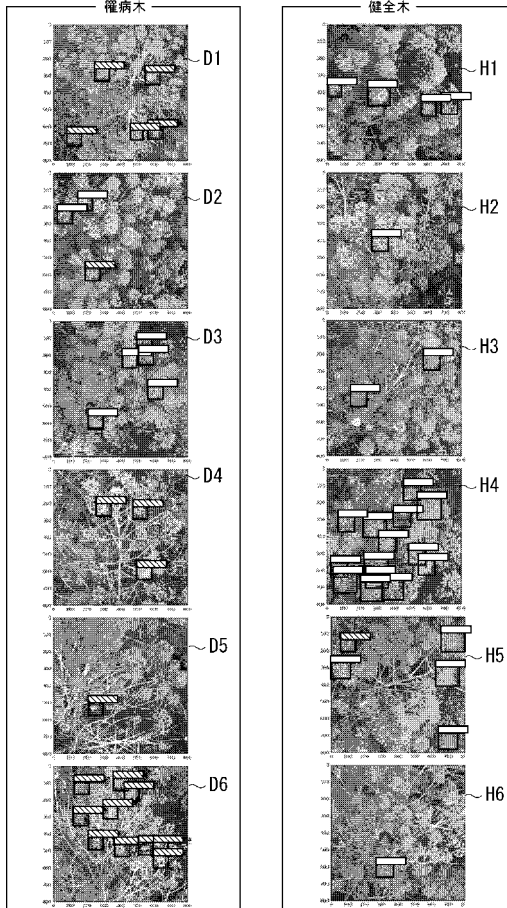
$$L_{conf}(x, c) = \sum_{i \in Pos} x_{ij}^p \log(\hat{c}_i^p) - \sum_{i \in Neg} \log(\hat{c}_i^p) \quad \text{where } \hat{c}_i^p = \frac{\exp(c_i^p)}{\sum_p \exp(c_i^p)}$$

(式C)

【図 1 3】

クローン	樹齢	Age1 (若年)	Age2 (壮年)	Age3 (老年)
P1	—	—	G34 32本	H29 27本
P3	H31	32本	G35 32本	H28 26本
P4	—	—	H34 27本	G29 14本

【図 1 4】



フロントページの続き

(72)発明者 増本 裕介
東京都港区港南二丁目1番1号 株式会社電通国際情報サービス内

(72)発明者 荒井 利晃
東京都中央区京橋三丁目1番1号 株式会社ブリヂストン内

(72)発明者 内島 和人
東京都中央区京橋三丁目1番1号 株式会社ブリヂストン内

(72)発明者 村瀬 正典
東京都中央区京橋三丁目1番1号 株式会社ブリヂストン内

(72)発明者 内山 俊宏
東京都中央区京橋三丁目1番1号 株式会社ブリヂストン内

Fターム(参考) 5L096 AA02 AA06 DA01 EA02 EA03 EA15 EA16 EA39 FA62 FA64
FA66 FA69 GA51 GA55 HA11 JA11 JA22 KA04