

(12) 特許協力条約に基づいて公開された国際出願

(19) 世界知的所有権機関  
国際事務局

(43) 国際公開日  
2020年10月8日(08.10.2020)



(10) 国際公開番号  
**WO 2020/203651 A1**

- (51) 国際特許分類:  
G16H 50/20 (2018.01) A61B 10/00 (2006.01)  
A61B 5/00 (2006.01)
- (21) 国際出願番号: PCT/JP2020/013684
- (22) 国際出願日: 2020年3月26日(26.03.2020)
- (25) 国際出願の言語: 日本語
- (26) 国際公開の言語: 日本語
- (30) 優先権データ:  
特願 2019-067229 2019年3月29日(29.03.2019) JP  
特願 2019-206765 2019年11月15日(15.11.2019) JP
- (71) 出願人: 国立大学法人筑波大学 (UNIVERSITY OF TSUKUBA) [JP/JP]; 〒3058577 茨城県つくば市天王台一丁目1番1 Ibaraki (JP).

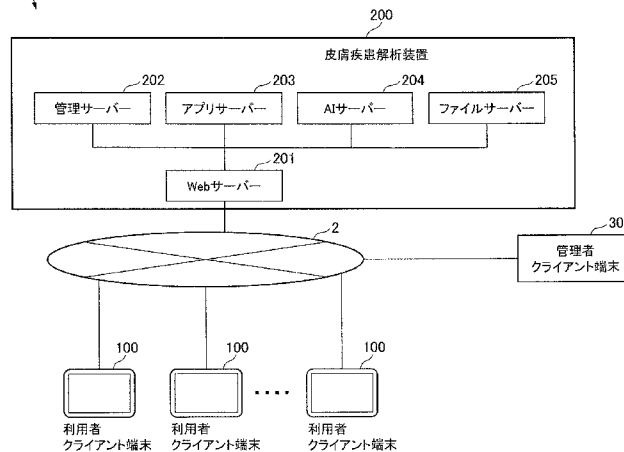
S O I N N 株式会社 (SOINN INC.) [JP/JP]; 〒1940004 東京都町田市鶴間八丁目4番30号 Tokyo (JP). 株式会社生命科学インスティテュート (LIFE SCIENCE INSTITUTE, INC.) [JP/JP]; 〒1008251 東京都千代田区丸の内一丁目1番1号 Tokyo (JP).

(72) 発明者: 藤澤 康弘 (FUJISAWA Yasuhiro); 〒3058577 茨城県つくば市天王台一丁目1番1 国立大学法人筑波大学内 Ibaraki (JP). 岩下 耕大 (IWASHITA Kodai); 〒1940004 東京都町田市鶴間八丁目4番30号 S O I N N 株式会社内 Tokyo (JP). 石田 満理 (ISHIDA Mitsuyoshi); 〒1010047 東京都千代田区内神

(54) Title: SKIN DISEASE ANALYZING PROGRAM, SKIN DISEASE ANALYZING METHOD, SKIN DISEASE ANALYZING DEVICE, AND SKIN DISEASE ANALYZING SYSTEM

(54) 発明の名称: 皮膚疾患解析プログラム、皮膚疾患解析方法、皮膚疾患解析装置及び皮膚疾患解析システム

[図1]



- 100 User client terminal
- 200 Skin disease analyzing device
- 201 Web server
- 202 Management server
- 203 Application server
- 204 AI server
- 205 File server
- 300 Administrator client terminal

(57) Abstract: Provided are a skin disease analyzing program, a skin disease analyzing method, a skin disease analyzing device, and a skin disease analyzing system capable of analyzing skin diseases more accurately. A program according to the present invention causes a computer to execute a second step of predicting the type of a skin tumor, with respect to



WO 2020/203651 A1

田一丁目13番4号 株式会社生命科学インスティテュート内 Tokyo (JP).

- (74) 代理人: 高岡 亮一, 外 (TAKAOKA Ryoichi et al.); 〒1710021 東京都豊島区西池袋5-4-7 池袋トーセイビル5階 高岡IP特許事務所 Tokyo (JP).
- (81) 指定国(表示のない限り、全ての種類の国内保護が可能): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW.
- (84) 指定国(表示のない限り、全ての種類の広域保護が可能): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), ユーラシア (AM, AZ, BY, KG, KZ, RU, TJ, TM), ヨーロッパ (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

添付公開書類:

- 一 国際調査報告 (条約第21条(3))

an image to be analyzed, which is an image of a skin tumor, by means of a first learned model that has been subjected in advance to machine learning using images of affected parts for various skin diseases, and either one or both of a first step and a third step, wherein the first step is a step for determining, in advance of the second step, whether the image to be analyzed is an image of a skin tumor, by means of a skin disease determination engine, and the third step is a step for re-predicting the type of the skin tumor with respect to the image to be analyzed, if the determination result in the second step is one of more than one type of skin tumor that are easily mistaken for one another, by means of a second learned model that has been subjected to machine learning using images of affected parts for specific skin diseases, including skin tumors that are easily mistaken for one another.

(57) 要約: より高い精度で皮膚疾患を解析することができる皮膚疾患解析プログラム、皮膚疾患解析方法、皮膚疾患解析装置及び皮膚疾患解析システムを提供する。本発明のプログラムは、コンピュータに、皮膚腫瘍の画像である解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた第1学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、第1ステップ又は第3ステップのいずれか、あるいは両方を実行させ、第1ステップは、第2ステップに先立って、皮膚疾患判定エンジンにより、解析対象画像が皮膚腫瘍の画像であるか否かを判定するステップであり、第3ステップは、第2ステップの判定結果が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより、解析対象画像に対して皮膚腫瘍の種類を再予測するステップである。

## 明 細 書

発明の名称：

皮膚疾患解析プログラム、皮膚疾患解析方法、皮膚疾患解析装置及び皮膚疾患解析システム

### 技術分野

[0001] 本発明は、皮膚疾患解析プログラム、皮膚疾患解析方法、皮膚疾患解析装置及び皮膚疾患解析システムに関する。

### 背景技術

[0002] 従来、皮膚に異常を発見した場合、皮膚科や内科その他の医院や病院へ通院することが一般的であり、そこで医師は患者の皮膚を肉眼で観察し診断を行い、疾患名を特定していた。しかしながら例えば「ほくろ」と「メラノーマ（悪性黒色腫）」のように形状が似通っているものを区別しにくい場合があった。

[0003] 近年、ダーモスコープという光源を有する拡大鏡が用いられるようになり、医師が皮膚の細かい部分を観察することによって、よりの確に疾患名を特定できるようになった。しかしながら、ダーモスコープは、どの医療機関にも設置されているわけではなく、しかも使用するために一定程度の熟練を要し、また皮膚科の専門的な知識も必要である。また、ダーモスコープを使用する医師と患者とが物理的に近接している必要がある。

[0004] これに対し、インターネットの普及と通信速度の向上により、またスマートフォンやタブレットなどのカメラ付きモバイル端末が一般的になり、デジタル映像の撮影や伝送がきわめて容易になってきたことから、画像を解析することにより疾患名を判定するシステムの開発が進められるようになった。

[0005] 例えば特許文献1には、利用者端末から皮膚疾患解析センタ装置に送られた画像を、該センタ装置の内部に蓄積された皮膚疾患解析のためのデータと対象解析を行い、皮膚疾患を予測して予測疾患名を提示するシステムが開示されている。

## 先行技術文献

### 特許文献

[0006] 特許文献1：特開2005-58398号公報

### 発明の概要

#### 発明が解決しようとする課題

[0007] しかしながら、特許文献1には具体的にどの疾患を判定可能なのかが示されておらず、また、具体的な精度が開示されておらず、実用化は困難であると考えられる。

[0008] 本発明は以上のような課題を解決するためになされたものであり、より高い精度で皮膚疾患を解析することができる皮膚疾患解析プログラム、皮膚疾患解析方法、皮膚疾患解析装置及び皮膚疾患解析システムを提供することを目的とする。

#### 課題を解決するための手段

[0009] 上記課題を解決するために、本発明は、コンピュータにより実行される皮膚疾患解析プログラムであって、前記コンピュータに、皮膚腫瘍の画像である解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた第1学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、第1ステップ又は第3ステップのいずれか、あるいは両方を実行させ、前記第1ステップは、前記第2ステップに先立って、皮膚疾患判定エンジンにより、解析対象画像が皮膚腫瘍の画像であるか否かを判定するステップであり、前記第3ステップは、前記第2ステップの判定結果が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより、解析対象画像に対して皮膚腫瘍の種類を再予測するステップである、ことを特徴とする。

[0010] また、上記課題を解決するために、本発明は、コンピュータにより実行される皮膚疾患解析プログラムであって、前記コンピュータに、皮膚疾患判定

エンジンにより、解析対象画像が皮膚腫瘍の画像であるか否かを判定する第1ステップと、前記第1ステップによって前記解析対象画像が皮膚腫瘍の画像であると判定された場合、該解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、を実行させる、ことを特徴とする。

[0011] また、本発明は、コンピュータにより実行される皮膚疾患解析プログラムであって、前記コンピュータに、皮膚疾患判定エンジンにより、皮膚疾患の患部の画像によって機械学習させた第1学習済みモデルにより該解析対象画像の皮膚腫瘍の種類を予測する第2ステップと、前記第2ステップによって前記解析対象画像が悪性黒色腫と互いに誤判定されやすい皮膚腫瘍の1種と判定された場合に、当該誤判定されやすい皮膚腫瘍及び悪性黒色腫を含む患部の画像によって機械学習させた第2学習済みモデルにより皮膚腫瘍の種類を再予測する第3ステップと、を実行させる、ことを特徴とする。

### 発明の効果

[0012] 本発明によれば、より高い精度で皮膚疾患を解析することができる皮膚疾患解析プログラム、皮膚疾患解析方法、皮膚疾患解析装置及び皮膚疾患解析システムを提供することができる。

### 図面の簡単な説明

[0013] [図1]本発明の一実施形態に係る皮膚疾患解析システム1のハードウェア構成を示すブロック図である。

[図2]図1に示したA1サーバー204の機能的構成を示すブロック図である。

[図3]図1に示した皮膚疾患解析システム1の動作の概略を説明する図である。

[図4]皮膚疾患解析システム1で実行される皮膚疾患解析プログラムの処理の一例を示すフローチャートである。

[図5]皮膚疾患解析装置200で実行される除外判定の処理を示すフローチャートである。

[図6]皮膚疾患解析システム1による皮膚疾患解析の結果が悪性腫瘍である場合の表示例を示す図である。

[図7]皮膚疾患解析システム1による皮膚疾患解析の結果が良性腫瘍である場合の表示例を示す図である。

[図8]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図9]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図10]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図11]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図12]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図13]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図14]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図15]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図16]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図17]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図18]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図19]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図20]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図21]悪性メラノーマと診断された症例について複数の画像データを有し、且つ判定結果（AI判定第一候補）が異なる3例を示す表である。

[図22]確信度と正解率の関係を示す表である。

[図23]悪性メラノーマ（MM）及び母斑細胞母斑（NCN）について複数枚の画像が判定された例を示す表である。

[図24]本発明に用いられるモデルの学習曲線を示す例である。

[図25]本発明に用いられるモデルの学習曲線を示す例である。

[図26]本発明に用いられるモデルを学習させた学習済みモデルにより、テストデータおよび学習データを判定した場合の正解率と標準偏差を示す表である。

[図27]DenseNet201を学習させた学習済みモデルを用いてテストデータを判定した場合の混同行列を示す表である。

[図28]皮膚疾患解析装置200で実行される再予測の処理を示すフローチャートである。

[図29]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図30]本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。

[図31]本実施形態の皮膚疾患解析システム（皮膚疾患判定エンジン、第1学習済みモデル、第2学習済みモデルの3つの分類器を搭載したもの）による判定結果の一例を示す表である。

### 発明を実施するための形態

[0014] 本発明は、例えば深層ニューラルネットワークを用いた機械学習により、入力された画像を解析し、その画像からタイプの異なる皮膚腫瘍を判定するシステムを提供する。

本発明は、入力される画像は皮膚腫瘍の画像のみであるということに限定

されず、例えば画像の質が悪かったり、炎症性疾患等の皮膚腫瘍以外の疾患の画像であったり、更には皮膚腫瘍とは全く関係のない画像を間違えて入力した場合などでも対応可能である。

[0015] 例えば皮膚がんは、太陽光中の紫外線が主な発症原因とされており、また、白人に多く、黄色人種に少なく、黒人には極めてまれである。例えば、悪性黒色腫の発生率は日本では年間1500～2000人であるのに対し、米国では年間91000人程度とされている。

日本では症例数が少ないことから疾患の認知度が低いことに加え、悪性黒色腫と黒子（ほくろ）との区別が難しいことが多い。例えば患部が黒色調を呈しない場合は、患者本人がにきびやおできであると素人判断して処置を行わない（病院に行かない）可能性がある。また、患者が病院に行った場合であっても皮膚科専門医以外にかかった場合には、正確な診断が下されない可能性がある。その結果、病気が進行してしまい予後が悪化する場合がある。

[0016] 悪性黒色腫以外にも悪性腫瘍は多数あり、これも熟練した皮膚科の専門医でなければそれらを的確に区別することは困難である。

一方で、皮膚腫瘍は皮膚表面に症状が現れ、なんらかの変化を本人や他人が認識することができる。このため、気が付いた時に手軽に病態を判定することができれば、早期に皮膚腫瘍を発見でき、完治させることが期待できる。そこで本発明は、一般内科医、総合診療医など、かかりつけ医でも手軽に扱うことができ、皮膚腫瘍の診断をサポートすることができる、皮膚疾患解析プログラム、皮膚疾患解析方法、皮膚疾患解析装置及び皮膚疾患解析システムを提供する。

[0017] 皮膚疾患には、メラノーマのような単発性の病変を示すものと、アトピー性皮膚炎のような病変が面状に広がり示すものがある。このうち、皮膚腫瘍は一般的には単発性のものであるが、中には、菌状息肉症（MF）のように多発性のものや面状を示すものが稀に見られる。一方、炎症性皮膚疾患は一般的には面状であるが、単発性のものもある。

本明細書において、「皮膚腫瘍」とは病変が単発性（多発性であっても、

個々の病変が正常な皮膚に囲まれており、他の病変と独立して認識できるものを含む)である皮膚疾患をいう。これら「皮膚腫瘍」として具体的には例えば、以下に示す24クラスのもの挙げられる。悪性腫瘍としては、日光角化症(AK)、皮角日光角化症(AK horn)、ボーエン病(Bowen)、有棘細胞癌(SCC)、基底細胞癌(BCC)、無色素基底細胞癌(BCCameIa)、乳房外パジェット病(EMPD)、悪性メラノーマ(MM、以下「悪性黒色腫」ともいう。)、無色素悪性メラノーマ(MMameIa)、血管肉腫(AS)が挙げられる。また、良性腫瘍としては、汗孔腫(Poroma)、無色素汗孔腫(PoromameIa)、皮脂母斑(SebaceousN)、脂漏性角化症(SK)、無色素脂漏性角化症(SKameIa)、青色母斑(BlueN)、先天性色素性母斑(CongenitalN)、母斑細胞母斑(NCN)、無色素母斑細胞母斑(NCNameIa)、スピッツ母斑(Spitz)、無色素スピッツ母斑(SpitzameIa)、黒子(Lentigo)、扁平母斑(Spilus)、化膿性肉芽腫(PG)が挙げられる。

[0018] なお、菌状息肉症(MF)は、分類上は皮膚腫瘍に属するが、血液腫瘍であり、必ずしも腫瘍性の病変を作らないことや、多発性の病変を示すことがあるため、本明細書においては皮膚腫瘍に含まれないものとする。

本発明において、皮膚腫瘍の患部を撮影するカメラは、一定以上の解像度を有していれば特に機種によらず用いることができる。写した患部の写真をそのまま、又は加工して、遠隔からでも皮膚疾患解析装置に入力可能な利便性から、カメラを内蔵したスマートフォンやタブレットを用いるのが好ましい。

また、皮膚疾患解析装置において判定の精度を上げるには、患部の写真画像に、皮膚以外の部分が写っていないことが好ましい。このため、本発明では、写真画像を皮膚疾患解析装置に入力する前に、皮膚以外の箇所が写りこむことなく、且つ病変がほぼ中央部に来るように画像をトリミングするアプリケーションを用いることが好ましい。このトリミングするアプリケーショ

ンは、患部を撮影した画像を、皮膚疾患判定エンジン及び学習済みモデルで解析しやすくするために、画像を予め指定されたフォーマットに合わせるためのプログラムである。

[0019] <皮膚疾患解析システム1のハードウェア構成>

図1は、本発明の一実施形態に係る皮膚疾患解析システム1のハードウェア構成を示すブロック図である。皮膚疾患解析システム1は図示の通り、1以上の利用者クライアント端末100と、皮膚疾患解析サーバーである皮膚疾患解析装置200と、管理者クライアント端末300と、を含む。利用者クライアント端末100及び管理者クライアント端末300は、皮膚疾患解析装置200とネットワーク2を介して接続する。ネットワーク2は、インターネットなどの有線及び無線通信システムである。本実施形態に係る皮膚疾患解析プログラム自体及びプログラムの実行に必要なデータは、利用者クライアント端末100、皮膚疾患解析装置200及び管理者クライアント端末300の記憶装置に記憶される。皮膚疾患解析装置200の記憶装置は例えばファイルサーバー205であってもよい。

[0020] 皮膚疾患解析装置200は、パーソナルコンピュータ、ワークステーション、汎用コンピュータなどの如何なるコンピュータであってもよいし、これらの組み合わせであってもよい。皮膚疾患解析装置200は、1台のコンピュータであってもよいし、複数台のコンピュータであってもよい。

皮膚疾患解析装置200は、Webサーバー201、管理サーバー202、アプリサーバー203、AIサーバー204、及びファイルサーバー205を有する。皮膚疾患解析装置200の各サーバーは、皮膚疾患解析プログラムを実行することにより、皮膚疾患解析装置200の動作を制御する制御部として機能する。

Webサーバー201は、ネットワーク2を介した通信を行う。管理サーバー202は、皮膚疾患解析システム1のアカウント管理などを行う。アプリサーバー203は、利用者クライアント端末100や管理者クライアント端末300を操作するユーザとの間のユーザインターフェースや画像データ

のトリミングなどの各種アプリケーションを提供する。AIサーバー204は、利用者クライアント端末100から入力された画像に対して皮膚疾患解析を実行する。ファイルサーバー205は、各種データの記憶及び管理を行う。Webサーバー201、管理サーバー202、アプリサーバー203、AIサーバー204及びファイルサーバー205は互いに接続され、各種データの送受信を行う。

[0021] 皮膚疾患解析装置200のファイルサーバー205には、医療施設についての情報である施設情報、利用者クライアント端末100の操作者（医師、医療関係者、患者、システム管理者等）のアカウントについての情報であるアカウント情報、利用者クライアント端末100から入力された各種データ、及び皮膚疾患解析システム1の動作に必要なプログラムやデータ等が記憶される。

[0022] 利用者クライアント端末100は、スマートフォン、フィーチャーフォン、PDA（Personal Digital Assistant）、又はタブレット型コンピュータ等の携帯端末であってもよいし、デスクトップ型コンピュータ等であってもよい。利用者クライアント端末100は、タッチパネルで操作可能であるのが望ましい。利用者クライアント端末100は、医師が操作することが望ましいが、医師以外の医療関係者や患者本人が操作してもよい。

[0023] 利用者クライアント端末100は、利用者クライアント端末100の操作者（医師、被検査者、医療施設管理者等）のアカウント管理、患部の写真撮影、撮影画像の皮膚疾患解析装置200への送信、皮膚疾患解析装置200による解析結果等の各種レポートの表示等を実行する。患部の写真撮影は、利用者クライアント端末100以外のカメラなどの撮像装置で行い、その撮像装置で撮影した画像データを利用者クライアント端末100に入力してもよい。

[0024] 管理者クライアント端末300は、スマートフォン、フィーチャーフォン、PDA（Personal Digital Assistant）、又

はタブレット型コンピュータ等の携帯端末であってもよいし、デスクトップ型コンピュータ等であってもよい。管理者クライアント端末300は、利用者クライアント端末100と同じ構成であってもよいし、異なる構成であってもよい。

[0025] 管理者クライアント端末300は、管理者クライアント端末300の操作者（システム管理者等）のアカウント管理、及び皮膚疾患解析システム1の運用状況等の各種レポートの表示等を実行する。

[0026] <A1サーバー204の機能的構成>

図2は、図1に示したA1サーバー204の機能的構成を示すブロック図である。

[0027] A1サーバー204は、学習済みモデル210及び皮膚疾患判定エンジン211を有する。学習済みモデル210は、予め各種皮膚疾患の患部の画像により機械学習させた、皮膚疾患の種類を予測するための学習済みモデルである。皮膚疾患判定エンジン211は、皮膚疾患と皮膚疾患以外とを判定、あるいは皮膚腫瘍と皮膚腫瘍以外とを判定する。A1サーバー204は、詳しくは後述するように、利用者クライアント端末100から送信されてきた画像データに対して皮膚疾患の解析を行う。

[0028] <皮膚疾患解析システム1の動作説明>

図3は、図1に示した皮膚疾患解析システム1の動作の概略を説明する図である。図3は、利用者クライアント端末100がスマートフォンである場合を例に示している。

[0029] まず、利用者クライアント端末100と別体のカメラ又は利用者クライアント端末100に内蔵されたカメラによって患部を撮影する。別体のカメラで撮影した場合は、その撮影した画像データを着脱可能な記憶媒体を介して利用者クライアント端末100に送ってもよいし、通信により画像データを利用者クライアント端末100に送ってもよい。

[0030] その後、撮影した画像データから皮膚以外の部分を除外するようトリミングを行う。このトリミングは利用者クライアント端末100で実行されるア

アプリケーションプログラムで行ってもよい。また、利用者クライアント端末100ではブラウザ（webブラウザ）を実行して皮膚疾患解析装置200のWebサーバー201に接続し、皮膚疾患解析装置200のアプリサーバー203で実行されるアプリケーションプログラムでトリミングを行ってもよい。このトリミングを実行するアプリケーションは、皮膚以外の箇所が写りこむことなく、且つ病変がほぼ中央部に来るように画像をトリミングすることが好ましい。

[0031] 続いて、利用者クライアント端末100は、トリミングした画像データを皮膚疾患解析装置200にアップロードする。皮膚疾患解析装置200側で画像データのトリミングを行う場合には、利用者クライアント端末100は、トリミング前の画像データを皮膚疾患解析装置200にアップロードする。

アップロードする画像は1つの症例について1枚以上あればよいが、画像が不鮮明であった場合の撮りなおしを避けるため、あるいは、撮影角度、距離、明度等の画像状況により誤判定となる可能性があることから2枚以上の複数の画像をアップロードして判定に用いることが好ましい。アップロードの画像があまり多すぎても煩雑になるので、2枚から10枚の画像をアップロードするのが好ましく、3枚から5枚の画像をアップロードするのが特に好ましい。

[0032] 画像データのアップロードを受けた皮膚疾患解析装置200では、AIサーバー204によって、詳しくは後述するように除外判定及びクラス分類を行う。AIサーバー204による解析の結果は、Webサーバー201を介して利用者クライアント端末100に送信され、これを受けた利用者クライアント端末100はブラウザにて解析結果を表示する。このとき、例えば、疾患名とその疾患である確率（「確信度」とも表現される）とを、確率が高い順に第三候補まで表示する。あるいは、疾患名を表示せず単に悪性であるか良性であるかを表示することもできる。また、このとき、その疾患の対処方法を表示してもよい。対処方法としては、経過観察、患部の切除などが含

まれる。

[0033] <皮膚疾患解析システム1の処理フローの説明>

図4は、皮膚疾患解析システム1で実行される皮膚疾患解析プログラムの処理の一例を示すフローチャートである。この例では、皮膚疾患を解析する処理が、利用者クライアント端末100及び皮膚疾患解析装置200で実行される。

[0034] まず、利用者クライアント端末100は、ユーザの操作に応じて皮膚疾患解析装置200に接続し、皮膚疾患解析装置200に対して、皮膚疾患解析システム1の利用要求を送信する（ステップS401）。皮膚疾患解析装置200では、利用者クライアント端末100からの利用要求を受け取る（ステップS451）。この利用要求には、利用者クライアント端末100のユーザについて予め登録したID及びそのIDに対応付けられたパスワードを含む。ID及びパスワードは、例えばファイルサーバー205に予め保存されて登録されている。

[0035] 管理サーバー202は、ファイルサーバー205に保存されているID及びパスワードと、利用者クライアント端末100からの利用要求に含まれているID及びパスワードとを照合し、利用要求を送信してきたユーザが正当な利用者であるかを確認する（ステップS452）。

[0036] 皮膚疾患解析装置200では、ステップS452において、利用要求を送信してきたユーザが正当な利用者でないと判定された場合、皮膚疾患解析装置200は、利用者クライアント端末100にその旨を送信して利用を拒否する。

ステップS452において、利用要求を送信してきたユーザが正当な利用者であると判定された場合、皮膚疾患解析装置200は、利用者クライアント端末100に利用目的を問い合わせる利用目的照会を行う（ステップS453）。利用目的照会は、ユーザに、例えば「診断目的」、「研究目的」などの入力を依頼するものであってもよい。

利用者クライアント端末100を操作するユーザは利用目的の回答を皮膚

疾患解析装置 200 に送信し（ステップ S 402）、皮膚疾患解析装置 200 は利用目的を受け取る（ステップ S 454）。

[0037] 続いて皮膚疾患解析装置 200 では、患部写真・患部情報送信の要求を利用者クライアント端末 100 に送信する（ステップ S 455）。患部写真・患部情報送信の要求を受け取ったら、利用者クライアント端末 100 は、患部写真を撮影し、その画像データを皮膚疾患解析装置 200 に送信する（ステップ S 403）。利用者クライアント端末 100 は、ステップ S 403 で患部写真を送信した後、ユーザに向けて送信完了画面を表示する（ステップ S 404）。なお、患部写真は、ステップ S 401 の利用要求の前に撮影しておいてもよい。図 4 においてステップ S 455 及びステップ S 403 に記載の患部情報は、患部写真の画像データから上述のトリミングを施した画像データを含む。上述のようにトリミングは利用者クライアント端末 100 で行ってもよいし、皮膚疾患解析装置 200 で行ってもよい。トリミングを皮膚疾患解析装置 200 で行う場合は、患部情報はトリミングを施した画像データを含まない。

[0038] 本発明の好ましい実施態様において、皮膚疾患解析装置 200 は、受信した患部写真に対して除外判定を行う（S 456）。この除外判定については、図 5 を参照して説明する。

[0039] 図 5 は、皮膚疾患解析装置 200 で実行される除外判定の処理を示すフローチャートである。皮膚疾患解析装置 200 は、受信した患部写真の画像データが、適用対象画像であるか、除外する画像であるかを判断する（ステップ S 501）。ここでは、例えば皮膚画像を適用対象画像とすることができる。皮膚画像か否かは、過去の皮膚画像を学習することで判断するようにしてもよい。除外する画像である場合には、「警告表示」として、ステップ S 457 に進む。適用対象画像である場合には、ステップ S 502 に進む。ステップ S 502 では、皮膚疾患解析装置 200 は、その画像データが、腫瘍画像であるかを判断する。腫瘍画像以外の画像、例えば炎症性画像である場合には、「警告表示」として、ステップ S 457 に進む。腫瘍画像である場

合には、「分類可」として、ステップS 4 5 8に進む。この除外判定の処理について詳しくは後述する。

[0040] 図4の説明に戻り、ステップS 4 5 6の除外判定で「警告表示」となった場合、皮膚疾患解析装置200は、利用者クライアント端末100に対して警告／再送信要求を送信する（S 4 5 7）。この「警告表示」は、利用者クライアント端末100から受信した患部写真が、皮膚疾患解析システム1で対象とする腫瘍画像ではないと判断されたことを意味し、ステップS 4 5 7では利用者クライアント端末100に対して警告するとともに、正しい患部写真の再送信を要求する。これを受けた利用者クライアント端末100では、ユーザに向けて警告表示を行う（ステップS 4 0 5）。ユーザは、この警告表示に対応し、患部写真を再度撮影するなどして画像データの再送信をするか、警告表示された画像データの皮膚疾患解析（クラス分類）を強制的に実行するかを選択し、その選択した指示を利用者クライアント端末100に入力する。

ユーザが画像データの再送信を選択した場合、利用者クライアント端末100は、ステップS 4 0 3に戻り、患部写真の画像データを皮膚疾患解析装置200へ再送信する。ユーザが警告表示された画像データの皮膚疾患解析（クラス分類）の強制的実行を選択した場合、皮膚疾患解析（クラス分類）の強制的実行の指示を皮膚疾患解析装置200へ送信する（ステップS 4 0 6）。皮膚疾患解析装置200は、強制的に分類判定を行う指示を受けた場合はステップS 4 5 8に進み、処理を続行する。

[0041] 利用者クライアント端末100から複数枚の患部の画像を送信できるシステムの場合には、送信された各画像についてステップS 4 5 6の除外判定が行われ、例えば、全ての画像について「腫瘍画像ではない」と判定された場合に利用者クライアント端末100に対して警告／再送信要求を送信する（S 4 5 7）。

更に、利用者クライアント端末100から3枚以上の患部画像を送信できるシステムにおいては、ステップS 4 5 6において何枚以上「腫瘍画像では

ない」と判定された場合に利用者クライアント端末100に対して警告／再送信要求を送信する（S457）のかを適宜設定することができる。

[0042] 皮膚疾患解析装置200は、ステップS458において、皮膚腫瘍のクラス分類判定を行う。このクラス分類について詳しくは後述する。ステップS458の判定結果は、腫瘍の良性、悪性の判定結果、その疾患名、その疾患名の疾患である確率を含む。皮膚疾患解析装置200は、ステップS459において、ステップS458の判定結果を利用者クライアント端末100に送信して処理を終了する。

[0043] ステップS458の判定結果を受信した利用者クライアント端末100は、その判定結果をユーザに向けて表示して（S407）、処理を終了する。ステップS407の表示例を図6及び図7に示す。図6は、皮膚疾患解析システム1による皮膚疾患解析の結果が悪性腫瘍である場合の表示例を示す図である。図7は、皮膚疾患解析システム1による皮膚疾患解析の結果が良性腫瘍である場合の表示例を示す図である。

[0044] 図6の例では、判定の結果、確率が最も高い疾患と、次に確率が高い疾患の両方が悪性腫瘍であり、悪性腫瘍の可能性がある旨の表示をしている。図7の例では、判定の結果、確率が上位3番目までの疾患が良性腫瘍であり、良性腫瘍の可能性が高い旨の表示をしている。

[0045] なお、ステップS458の判定結果の履歴は、ファイルサーバー205に蓄積しておき、利用者クライアント端末100を操作するユーザ又は管理者端末300の操作者が閲覧可能にしてもよい。また、判定結果の履歴は、利用者クライアント端末100を操作するユーザに対応付けてもよいし、判定した画像の患者に対応付けて管理してもよい。

[0046] 図8は、本実施形態の皮膚疾患解析システム1による判定結果の一例を示す表である。図8では、横に専門医による診断結果を列挙し、その診断をされた患部画像を皮膚疾患解析システム1によって判定した結果（本発明による出力）を縦に列挙している。例えば、横に疾患名が並ぶ中で最左の列は「日光角化症」と診断された患者の画像であり、この総数は21件である。皮

膚疾患解析システム1による判定結果は、この21件のうち、7件を「日光角化症」と判定し、2件を「皮角日光角化症」と判定し、5件を「ボーエン病」と判定し、1件を「有棘細胞癌」と判定し、2件を「無色素基底細胞癌」と判定し、1件を「母斑細胞母斑」と判定し、3件を「扁平母斑」と判定した。この判定結果によれば、悪性腫瘍である日光角化症21件に対し、悪性の腫瘍と判定したものが17件であり、良性の腫瘍と判定したものが4件であり、悪性腫瘍の感度として81%という十分な感度が得られた。

図8及び後述の図9、図29に示された通り、悪性腫瘍は悪性腫瘍同士で互いに誤判定し、良性腫瘍は良性腫瘍同士で互いに誤判定する傾向にある。これは画像的に悪性腫瘍同士が互いに類似し、良性腫瘍同士が互いに類似していることを表している。このことから、多数クラス（例えば14～24クラス）判定の結果を用いて、悪性腫瘍か良性腫瘍かを予測することが可能となる。

[0047] <A1サーバー204の動作説明>

本実施形態のA1サーバー204で実行されるプログラムは、画像データ（解析対象画像）から皮膚腫瘍画像以外の画像を除外する判定を行う第1ステップ（図4のステップS456）と、皮膚腫瘍画像であるとして、第1ステップで除外されなかった画像について、皮膚腫瘍のうちどの種類かを判定する第2ステップ（図4のステップS458）とを有する。第1ステップは、例えば、皮膚疾患判定エンジン211により、患部画像の画像データが皮膚腫瘍画像であるか否かを判定する。第2ステップは、例えば、皮膚疾患判定エンジン211が、第1ステップによって皮膚腫瘍画像と判定された患部画像の画像データの皮膚腫瘍の種類を、学習済みモデル210により予測する。

[0048] <第1ステップ>

第1ステップは、入力される画像を皮膚腫瘍に絞り込むことを目的としている。第2ステップで用いる分類器は良性腫瘍か悪性腫瘍であるかの2クラスの判定や、悪性の上皮細胞系細胞の腫瘍、悪性のメラノサイト系細胞の腫瘍

、良性の上皮細胞系細胞の腫瘍、良性のメラノサイト系細胞の腫瘍の4クラスのいずれかの判定や、これに悪性の血管成分の腫瘍、良性の血管成分の腫瘍を加えた6クラスのいずれかの判定や、さらに細かく分類した14~24クラスあるいはそれ以上の皮膚腫瘍の種類を判定するものであるが、この分類器に入力される画像が皮膚腫瘍の画像であることを前提としている。従って、皮膚腫瘍の画像以外の画像を入力した場合でも良性または悪性の判定や、4~24クラスのいずれの種類であるかの判定を行うこととなる。即ち、例えば炎症性皮膚疾患の画像であっても皮膚腫瘍として判定され、また画像が不鮮明のため本来の腫瘍の病変が示されていない画像や、全く皮膚とは関係ない画像を間違えて入力した場合でも皮膚腫瘍として判定され、ユーザが誤認する一因となる。そこで、本実施形態においては、皮膚疾患以外の画像を除外するステップである第1ステップを設けることが好ましい。

[0049] この第1ステップ（「除外判定ステップ」と称することがある）の方式は、第2ステップに入力される画像を皮膚腫瘍画像に絞り込むことができれば特に制限はないが、例えば、

- (1) 皮膚腫瘍画像とそれ以外の画像とに1段で判定する方式、
- (2) まず皮膚以外の画像を除外し、残った皮膚画像の中から皮膚腫瘍画像とそれ以外の画像とに2段階で判定する方式、
- (3) まず、皮膚疾患以外の画像を除外し、残った皮膚疾患画像の中から皮膚腫瘍画像とそれ以外（炎症性皮膚疾患画像が含まれる）に2段階で判定する方式、
- (4) 色の分布により、まず皮膚以外のものが写っている画像を除外し、残った画像の中から皮膚腫瘍画像とそれ以外の画像に2段階で判定する方式、などが挙げられる。

[0050] 第1ステップにより除外判定された場合、ユーザに対して送信された画像が皮膚腫瘍の画像ではない可能性があるとして除外された旨のメッセージが伝えられる（ステップS405に対応）。具体的には例えば、「送られた画像は皮膚腫瘍画像ではない可能性があることを検知いたしました。お手数で

すが、送付した画像を再確認して下さい。確認後同じ画像を再送していただくか、撮り直したものを送付してください。」など、ユーザ側に確認するよう求めるメッセージが挙げられる。

[0051] <第2ステップ>

第2ステップは、分類器により皮膚腫瘍の種別を判定するステップである。一例として、皮膚腫瘍を24クラスに分類する方式について具体的に説明する。

[0052] ここで皮膚腫瘍の24クラスとは、悪性腫瘍としては、日光角化症（AK）、皮角日光角化症（AKhorn）、ボーエン病（Bowen）、有棘細胞癌（SCC）、基底細胞癌（BCC）、無色素基底細胞癌（BCCameila）、乳房外パジェット病（EMPD）、悪性メラノーマ（MM）、無色素悪性メラノーマ（MMameila）、血管肉腫（AS）であり、また、良性腫瘍としては、汗孔腫（Poroma）、無色素汗孔腫（Poromameila）、皮脂母斑（SebaceousN）、脂漏性角化症（SK）、無色素脂漏性角化症（SKameila）、青色母斑（BlueN）、先天性色素性母斑（CongenitalN）、母斑細胞母斑（NCN）、無色素母斑細胞母斑（NCNameila）、スピッツ母斑（Spitz）、無色素スピッツ母斑（Spitzameila）、黒子（Lentigo）、扁平母斑（Spilus）、化膿性肉芽腫（PG）である。

[0053] なお、本発明においては、これら24クラス以外の腫瘍についても、学習データに用いられる画像が用意できる限り各種の腫瘍をモデルに学習させた分類器により判定することが可能である。また、これら24クラスすべてを学習させなくても、例えば、症例の多い腫瘍クラスを選択して学習させた分類器により判定することも可能である。従って、第2ステップで推測される腫瘍の種類（クラス）は、通常2～100クラスであり、好ましくは4～50クラスであり、更に好ましくは10～30クラスである。

[0054] 分類器としては例えば、ImageNetのデータで重みの初期値を決定したモデルに、前記各疾患患部を撮影した皮膚腫瘍画像を機械学習させた学

習済みモデルを用いる。本発明に用いられるモデルとしては具体的には例えば、ResNet50、DenseNet169、DenseNet201、InceptionResNetV2、VGG16、VGG19、MobileNet、DenseNet121、Xception、InceptionV3等が挙げられるが、これらに限らない。

[0055] この分類器に、判定すべき皮膚腫瘍の画像を入力すると、一般的には分類器が判定した皮膚腫瘍の確からしさの順位とその確率が出力される。出力された値は、目的に応じてユーザに対して適切な数値や言葉等に変換し表示させることができる。

[0056] 例えば、かかりつけ医（総合診療医その他、通常なんらかの病気に罹ったと思われるときに最初に相談する医師）は、皮膚科の専門医ではないことが多いため、皮膚腫瘍の種類が困難な場合が想定される。しかし、仮に悪性の腫瘍の場合、放置しておくとし進行し、他の場所に転移して予後が悪化する可能性がある。従って、かかりつけ医向けの出力表示としては、良性または悪性との判定の表示を行い、悪性と分類器が予測した場合は、皮膚科専門医に紹介するなどの対応を促すメッセージを発する。これにより、悪性の皮膚腫瘍であっても早期に発見できれば転移を起こすことなく治療することができる。また、皮膚腫瘍は他人も自分も比較的その存在がわかりやすいため、患者が皮膚腫瘍についてかかりつけ医に気軽に相談することも考え得る。このとき、かかりつけ医がユーザとして本実施形態の皮膚疾患解析システム1を利用して皮膚腫瘍を判定できれば、必要に応じて皮膚科専門医を紹介し、早めに対処することが可能となる。この場合、ステップ（S407）において利用者クライアント端末100は、その判定結果として、良性か悪性かのみをユーザに向けて表示してもよい。

[0057] また、皮膚科専門医は皮膚腫瘍の種別を判断し、その種類によって治療方針を決める必要があると考えられる。そこで、皮膚科専門医がユーザとして本実施形態の皮膚疾患解析システム1を利用する場合にあっては、例えば、分類器が、可能性が高いと判定した上位3位まで乃至上位5位までの皮膚腫

瘍の種別を表示することが挙げられる。

- [0058] 本実施形態に係る皮膚疾患解析システム1は、例えば、管理サーバー202において、ユーザがかかりつけ医（皮膚科専門医以外の医師）か、ユーザが皮膚科専門医か、といったユーザ種別を管理することで、そのユーザ向けの表示を行い、ユーザ種別に応じてステップ（S407）における表示内容を異ならせる運用を行うこともできる。
- [0059] 皮膚科専門医は、本実施形態の皮膚疾患解析システム1により出力された、可能性の高い皮膚腫瘍の種類を参考とし、また腫瘍の表面形状、凹凸、大きさ、患者の年齢、患部の匂いなど、平面画像では計測困難な各種パラメータを捉え、総合的に判断して皮膚腫瘍を診断する。
- [0060] なお、A1サーバー204が皮膚疾患再予測エンジンを備え、皮膚疾患解析プログラムは皮膚疾患再予測エンジンによる再予測を行う第3ステップをコンピュータに実行させるものであってもよい。この第3ステップでは、皮膚疾患再予測エンジン（第2学習済みモデル）により、患部情報と、第2ステップによって予測された皮膚腫瘍の種類とから、皮膚疾患の種類を再予測する。この再予測については、図28を参照して説明する。
- [0061] 図28は、皮膚腫瘍クラス分類判定（S458A）を行った結果、他の疾患と誤判定されやすい疾患クラスに分類判定された場合、誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させて作成した分類器（第2学習済みモデル）を用いて、再判定を行う（S458B）ことを示している。例えば24クラス分類を行う分類器（第1学習済みモデル）は多種類の疾患の画像を学習するため、形状の類似した疾患を誤判定する場合がある。これに対し、特定の少数の疾患の画像のみで学習させて作成した分類器（再判定エンジン：具体的には例えば、基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑の4腫瘍クラスの再判定エンジン）により誤判定を起こしにくい疾患同士を、より正確に分類することができる。
- [0062] このとき、患部情報と皮膚腫瘍の種類とから皮膚疾患の種類を再予測するための学習済みモデルを用いてもよい。患部情報としては、患者の年齢、患

部の大きさ、患部の匂い、疾患の発生部位、患部の立体形状のうちの1つあるいは複数を含む。この患部情報は、図4のステップS455及びステップS403に記載の患部情報に相当し、ユーザが皮膚疾患解析装置200に送信することができる。第3ステップによる再予測の結果は、第2ステップによる予測の結果と同様に、利用者クライアント端末100に表示することができる。

[0063] 第2ステップにおける分類器の構成としては、14～24クラスの皮膚腫瘍を1段で判定することも可能であり、また2段以上のステップを有していても良い。2段で行う場合は、例えば、

(1) 第1段(ステップA)で良性腫瘍群と悪性腫瘍群に分け、第2段(ステップB)で良性腫瘍群と悪性腫瘍群のそれぞれを各疾患クラスに判定する方法、

(2) ステップAで色素性の腫瘍群と、無色素性の腫瘍群に分け、ステップBで色素性の腫瘍群と無色素性の腫瘍群のそれぞれを各疾患クラスに判定する方法、

(3) ステップAで各疾患(4クラス、14クラス、または17クラス等)に分類し、ステップBで各疾患がクラス分けされているものについてそれぞれのクラスに判定する方法、

などが挙げられる。

[0064] また、腫瘍の中には形態が画像的に類似し、画像診断において分類器(学習済みモデル)が錯誤(誤判定)しやすい組み合わせがある。そこで、例えば上記第2ステップで各疾患(14クラス、17クラス、21クラス、または24クラス等)クラスに判定した後、第3ステップとして誤判定しやすい特定の疾患、について再判定する方法により精度を向上することが期待できる。

つまり、第3ステップで用いる分類器は、第2ステップで用いる分類器が学習した疾患クラスの中から、いくつか特定の疾患クラスを選択して学習させたものである。従って、第3ステップで用いる分類器が学習する疾患クラ

スの数は、第2ステップで用いる疾患クラスの数よりも少ない。

また、ここで互いに誤判定されやすい疾患クラスの組み合わせとは、専門医が確定診断した特定の疾患の症例画像のうち分類器により概ね2%以上を別の特定の疾患と判定する場合、または、ある疾患の分類器が判定した特定の疾患の症例画像のうち実際の専門医により別の特定の疾患と診断されたものが概ね2%以上ある場合であり、これらが2つまたはそれ以上の疾患クラスにおいて互いに認められる組み合わせを言う。

具体的には例えば、図29において、実際の診断結果としてのMMは646枚であるが、このうち43枚(6.66%)は分類器(24クラス判定器)によりNCNと判定されている。一方、分類器(24クラス判定器)によりNCNと判定された画像は1305枚であるが、このうち実際にMMと診断された画像は43枚(3.30%)であるので、MMとNCNは互いに誤判定されやすい疾患クラスの組み合わせである。これと同様に、図29に示した判定結果を得た分類器においてはMM(悪性)とNCN(良性)に加え、SK(良性)とBCC(悪性)も互いに誤判定されやすい疾患クラスの組み合わせである。

また、実際に診断されたPoromameiaの画像は98枚であるが、このうち11枚は(11.22%)分類器(24クラス判定器)によりBCCと判定されている。一方、分類器によりPoromameiaと判定された画像は48枚であるが、このうち実際にBCCと診断された画像は6枚(12.50%)であるので、BCCとPoromameiaは互いに誤判定されやすい疾患クラスの組み合わせである。

また、これらの他にも例えば、Bowen(悪性)とSCC(悪性)、SCC(悪性)とBCC(悪性)、NCN(良性)とSpitz(良性)、NCN(良性)とLentigo(良性)等も互いに誤判定されやすい疾患クラスの組み合わせである。ここで、悪性腫瘍をスクリーニングする目的等で悪性か良性かの判定を行う場合、ある良性腫瘍とある悪性腫瘍とが互いに誤判定されやすい疾患クラスの組み合わせであった場合は、偽陰性、偽陽性を

起こすことから特に重要となる。

上述のように、悪性メラノーマ（MM）と母斑細胞母斑（NCN）は形状が非常に似ているため分類器が誤判定する可能性がある。そこで、第2ステップで悪性メラノーマまたは母斑細胞母斑と判定された場合、これら2種をより正確に区別するために、悪性メラノーマの画像及び母斑細胞母斑の画像のみで学習させたモデルを用いて、第3ステップで悪性メラノーマであるか母斑細胞母斑であるかを判定する。

[0065] また、悪性を見逃さないという観点からは、第2ステップで母斑細胞母斑と判定された場合に、第3ステップで悪性メラノーマの画像及び母斑細胞母斑の画像のみで学習させたモデルを用いて、再度悪性メラノーマであるか母斑細胞母斑であるかを判定する。この場合、第2ステップで悪性メラノーマと判定された場合には、第2ステップの判定結果がそのまま採用される。

[0066] また更に、悪性メラノーマや母斑細胞母斑と類似している腫瘍を第3ステップの判定に加えてもよい。具体的には悪性メラノーマ、基底細胞癌、脂漏性角化症、母斑細胞母斑の4種の形状が類似していると考えられるので、第2ステップでこれら4つの腫瘍と判定された場合に、第3ステップで、悪性メラノーマの画像、基底細胞癌の画像、脂漏性角化症の画像、母斑細胞母斑の画像のみで学習させたモデルを用いて、再度、これら4つの腫瘍のいずれであるかを再判定する。

[0067] 悪性を見逃さないという観点からは、第2ステップで脂漏性角化症または母斑細胞母斑と判定された場合に、第3ステップで、悪性メラノーマの画像、基底細胞癌の画像、脂漏性角化症の画像、母斑細胞母斑の画像のみで学習させたモデルを用いて、再度、これら4つの腫瘍のいずれであるかを判定する。この場合、第2ステップで悪性メラノーマまたは基底細胞癌と判定された場合には、第2ステップの判定結果がそのまま採用される。

[0068] なお、どの腫瘍が互いに類似し、分類器（AI）として間違えやすいかは第2ステップに使用する学習済みモデル（第1学習済みモデル）により異なると考えられるので、第2ステップに使用する第1学習済みモデルの出力内

容に応じて、第3ステップで再判定すべき腫瘍の種類を適宜選択することができる。

[0069] 例えば、第1学習済みモデルが14～24クラスの判定を行う場合、第3ステップに用いられる第2学習済みモデルは、14～24クラスから選択した、通常2～10クラス、好ましくは3～8クラス、更に好ましくは4～6クラスの腫瘍を特定して学習させたものが用いられる。

[0070] 本発明の好ましい実施態様においては、皮膚腫瘍の種類を予測する腫瘍クラス判定ステップ（第2ステップ）を行った場合、その腫瘍クラス判定ステップの判定結果が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の患部の画像によって機械学習させた第2学習済みモデルにより再判定を行う特定腫瘍クラス再判定ステップ（第3ステップ）を実行させる。

[0071] 本発明の好ましい実施態様においては、皮膚腫瘍の種類を予測する腫瘍クラス判定ステップ（第2ステップ）を行った場合、その腫瘍クラス判定ステップの判定結果が良性腫瘍の1種であって、当該良性腫瘍と誤判定されやすい皮膚腫瘍の1種が悪性腫瘍であった場合に、当該良性の皮膚腫瘍と悪性の皮膚腫瘍とを含む特定の患部の画像によって機械学習させた第2学習済みモデルにより再判定を行う特定腫瘍クラス再判定ステップ（第3ステップ）を実行させる。

[0072] 本発明の更に好ましい実施態様においては、互いに誤判定されやすい皮膚腫瘍の1種が悪性メラノーマを含む場合であり、すなわち、皮膚腫瘍の種類を予測する腫瘍クラス判定ステップ（第2ステップ）を行った場合、その腫瘍クラス判定ステップの解析結果が、悪性メラノーマと誤判定されやすい皮膚腫瘍の1種であった場合に、当該悪性メラノーマと誤判定されやすい皮膚腫瘍及び悪性メラノーマを含む患部の画像によって機械学習させた第2学習済みモデルにより再判定を行う特定腫瘍クラス再判定ステップ（第3ステップ）を実行させる。

[0073] 学習済みモデルによっては、上述の悪性メラノーマを含む組み合わせ以外

でも再判定を行うことが効果的な場合もある。例えば、無色素基底細胞癌、無色素脂漏性角化症、無色素母斑細胞母斑含む組み合わせが、互いに誤判定されやすいものとして挙げられる。

[0074] 以下、本実施形態の皮膚疾患解析システム1について、さらに詳細に説明する。

好ましい実施態様：

- ・ 患部画像の撮影手段としては、カメラ付きスマートフォンまたはカメラ付きタブレットのような携帯可能なものを用いるのが好ましい。
- ・ 本実施形態で用いるスマートフォンには患部画像を撮影するためのアプリケーションを備えるのが好ましい。
- ・ 患部画像を撮影するためのアプリケーションには、患部画像において腫瘍の部分を画面の中心部に配置し、正常な皮膚部分は画面の周縁部に配置するための機能を有していることが好ましい。このように画像を撮影することにより、皮膚腫瘍を正しく皮膚腫瘍と認識することが可能になる。
- ・ 患部画像のトリミングは、皮膚疾患解析システム1のユーザである医師がトリミングを行うアプリケーションを操作して行ってもよい。この場合、医師が患部画像を視認して、腫瘍の部分を画面の中心部に配置し、正常な皮膚部分を画面の周縁部に配置し、皮膚でない部分を除外するように操作することができる。
- ・ 患部画像は患者自身が撮影し、その撮影画像を医師に送信することで、皮膚疾患解析システム1のユーザである医師が、利用者クライアント端末100を操作して患部画像の画像データを皮膚疾患解析装置200に送信するようにしてもよい。この方式を採用すれば、患者が遠隔地にいた場合でも皮膚腫瘍の判定を行うことができる。

[0075] 以下、上述の第1ステップ、第2ステップ、第3ステップの実施態様を例示する。本発明は、第1ステップと第2ステップを有するもの、第2ステップと第3ステップを有するもの、第1～第3ステップを有するものが含まれる。ここで第1ステップは除外判定器、第2ステップは第1学習済みモデル

、第3ステップは第2学習済みモデルが用いられる。

実施態様1：

- ・第1ステップ：(1) 皮膚の腫瘍と(2) それ以外の各群に分類する。
- ・第2ステップ：(1) 皮膚の腫瘍において、皮膚腫瘍の種類を判定する
- ・第3ステップ：第2ステップの結果によっては、特定の皮膚腫瘍の種類を再判定する。

[0076] 実施態様2：

- ・第1ステップA：皮膚以外の画像を除外する。

第1ステップB：第1ステップAで残った画像を、(1) 皮膚の腫瘍(単発性の皮膚疾患)、(2) 皮膚の腫瘍以外(炎症性皮膚疾患、及び正常な皮膚が含まれる)の各群に分類する。

- ・第2ステップ：(1) 皮膚の腫瘍の群において、皮膚腫瘍の種類を判定する。
- ・第3ステップ：第2ステップの結果によっては、特定の皮膚腫瘍の種類を再判定する。

[0077] 実施態様3：

- ・第1ステップA：(1) 皮膚疾患(皮膚腫瘍と炎症性皮膚疾患が含まれる)と(2) 皮膚疾患以外の各群に分類する。

第1ステップB：(1) 皮膚疾患を、(3) 皮膚の腫瘍、(4) 炎症性疾患の各群に分類する。

- ・第2ステップ：(3) 皮膚の腫瘍において、皮膚腫瘍の種類を判定する。
- ・第3ステップ：第2ステップの結果によっては、特定の皮膚腫瘍の種類を再判定する。

[0078] 実施態様4：

- ・第1ステップ：(1) 皮膚腫瘍と(2) それ以外の各群に分類する。
- ・第2ステップA：(1) 皮膚腫瘍において、(3) 色素性腫瘍と(4) 無色素性腫瘍の各群に分類する。
- ・第2ステップB：(3) 色素性腫瘍、(4) 無色素性腫瘍のそれぞれにお

いて、皮膚腫瘍の種類を判定する。

・第3ステップ：第2ステップの結果によっては、特定の皮膚腫瘍の種類を再判定する。

[0079] 実施態様5：

・第1ステップ：(1) 皮膚腫瘍と(2) それ以外の各群に分離する

・第2ステップ：皮膚の腫瘍において、皮膚腫瘍の種類を判定する

・第3ステップ(下記のいずれかのステップ)

第3ステップ1：上記第2ステップの判定が日光角化症であった場合に、日光角化症、皮角日光角化症、ボーエン病、無色素脂漏性角化症の4種についての判定機に再入力し、日光角化症、皮角日光角化症、ボーエン病、無色素脂漏性角化症のいずれかであるかを判定する。

第3ステップ2：上記第2ステップの判定が基底細胞癌であった場合に、基底細胞癌、無色素基底細胞癌の2種についての判定機に再入力し、基底細胞癌、無色素基底細胞癌のいずれであるかを判定する。

第3ステップ3：上記第2ステップの判定が無色素基底細胞癌であった場合に、無色素基底細胞癌、日光角化症、有棘細胞癌、無色素脂漏性角化症の4種についての判定機に再入力し、無色素基底細胞癌、日光角化症、有棘細胞癌、無色素脂漏性角化症のいずれであるかを判定する。

第3ステップ4：上記第2ステップの判定がボーエン病であった場合に、ボーエン病、日光角化症、無色素スピッツ母斑の3種についての判定機に再入力し、ボーエン病、日光角化症、無色素スピッツ母斑のいずれであるかを判定する。

第3ステップ5：上記第2ステップの判定が無色素汗孔腫であった場合、無色素汗孔腫、悪性メラノーマ、無色素母斑細胞母斑の3種についての判定機に再入力し、無色素汗孔腫、悪性メラノーマ、無色素母斑細胞母斑のいずれであるかを判定する。

第3ステップ6：上記第2ステップの判定が無色素汗孔腫であった場合、無色素汗孔腫、悪性メラノーマ、基底細胞癌の3種についての判定機に再入

力し、無色素汗孔腫、悪性メラノーマ、基底細胞癌のいずれであるかを判定する。

第3ステップ7：上記第2ステップの判定が有棘細胞癌あった場合、有棘細胞癌、皮角日光角化症、無色素基底細胞癌、ボーエン病、無色素悪性メラノーマの5種についての判定機に再入力し、有棘細胞癌、皮角日光角化症、無色素基底細胞癌、ボーエン病、無色素悪性メラノーマのいずれであるかを判定する。

第3ステップ8：上記第2ステップの判定が基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑のいずれかであった場合、基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑の4種についての判定機に再入力し、基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑のいずれであるかを判定する。

第3ステップ9：上記第2ステップの判定が脂漏性角化症、母斑細胞母斑のいずれかであった場合、基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑の4種についての判定機に再入力し、基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑のいずれであるかを判定する。

第3ステップ10：上記第2ステップの判定が悪性メラノーマまたは母斑細胞母斑であった場合に、悪性メラノーマ、母斑細胞母斑の2種についての判定機に再入力し、悪性メラノーマ、母斑細胞母斑のいずれであるかを判定する。

第3ステップ11：上記第2ステップの判定が母斑細胞母斑であった場合に、悪性メラノーマ、母斑細胞母斑の2種についての判定機に再入力し、悪性メラノーマ、母斑細胞母斑のいずれであるかを判定する。

第3ステップ12：上記第2ステップの判定が無色素母斑細胞母斑であった場合に、無色素基底細胞癌、無色素脂漏性角化症、無色素母斑細胞母斑の3種についての判定機に再入力し、無色素基底細胞癌、無色素脂漏性角化症、無色素母斑細胞母斑のいずれであるかを判定する。

第3ステップ13：上記第2ステップの判定が無色素汗孔腫であった場合

、基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑の4種についての判定機に再入力し、基底細胞癌、悪性メラノーマ、脂漏性角化症、母斑細胞母斑のいずれであるかを判定する。

ここで、第3ステップ1～13は第2ステップの判定の後、いずれか1つを適宜選択して実行することができる。また、第2ステップ及び第3ステップを行う場合は、第1ステップを省略することもできる。

[0080] 本発明の好ましい実施態様は、皮膚腫瘍の種類を予測する腫瘍クラス判定ステップを行った場合、その腫瘍クラス判定ステップの解析結果が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより再判定を行う特定腫瘍クラス再判定ステップを実行させるものであるが、上記第3ステップ1～12のそれぞれに示した疾患クラスは、互いに誤判定し易い疾患クラスの組み合わせの例である。

[0081] また、上記第3ステップ13においては、第2ステップで判定した無色素汗孔腫が第3ステップにおける疾患の候補に入っていないが、無色素汗孔腫はその形態の多様性と症例の希少性により学習済みモデルが十分な学習を獲得していない場合があるので、無色素汗孔腫と誤判定されやすい悪性腫瘍である基底細胞癌や悪性メラノーマを良性に判定（偽陰性）することをなるべく避けるという目的で便宜的に用いることができる例である。

## 実施例 1

[0082] 本実施例では、分類器として、ImageNetで学習した重みをもつ公知の画像分類モデルの中から2種を選択して、それぞれ教師画像（上記の24クラスの皮膚腫瘍の画像を、合計7532枚を用いて学習させた（第1学習済みモデルの1例）。画像の内訳は、悪性腫瘍としては日光角化症（AK）が278枚、皮角日光角化症（AKhorn）が95枚、ボーエン病（Bowen）が419枚、有棘細胞癌（SCC）が1166枚、基底細胞癌（BCC）が1100枚、無色素基底細胞癌（BCCamelia）284枚、乳房外パジェット病（EMPD）が335枚、悪性メラノーマ（MM）が6

25枚、無色素悪性メラノーマ (MMame l a) が74枚、血管肉腫 (A S) が81枚であり、また、良性腫瘍としては、汗孔腫 (P o r o m a) が103枚、無色素汗孔腫 (P o r o m a m e l a) が87枚、皮脂母斑 (S e b a c e o u s N) が96枚、脂漏性角化症 (S K) 520枚、無色素脂漏性角化症 (S K a m e l a) が66枚、青色母斑 (B l u e N) が119枚、先天性色素性母斑 (C o n g e n i t a l N) が238枚、母斑細胞母斑 (N C N) が1165枚、無色素母斑細胞母斑 (N C N a m e l a) が133枚、スピッツ母斑 (S p i t z) が204枚、無色素スピッツ母斑 (S p i t z a m e l a) が36枚、黒子 (L e n t i g o) が42枚、扁平母斑 (S p i l l u s) が161枚、化膿性肉芽腫 (P G) が105枚であった。これらの画像はいずれも皮膚腫瘍の専門医が診断を行い、疾患が確定したものを撮影したものである。

学習機の性能は、画像を10分割し、9/10を教師(学習)画像、1/10をテスト画像とし、交差検証法を用いて評価した。

[0083] 本実施例によれば、全体の正答率はモデル1で68%、モデル2で69%であった。個々の判定結果を例示すると、モデル2において、有棘細胞癌の画像110枚について、分類器が有棘細胞癌と正しく判定したものが80枚、日光角化症と判定したものが4枚、ポーエン病と判定したものが4枚、基底細胞癌と判定したものが5枚、無色素基底細胞癌と判定したものが7枚、乳房外パジェット病と判定したものが2枚、悪性メラノーマと判定したものが1枚、脂漏性角化症と判定したものが1枚、無色素母斑細胞母斑と判定したものが4枚、化膿性肉芽腫と判定したものが1枚であった。即ち、有棘細胞癌の画像について正しく有棘細胞癌と判定した割合(感度: R e c a l l)は73%であった。

[0084] 一方、分類器が有棘細胞癌と判定した109枚の患部画像のうち、実際の疾患が有棘細胞癌であるものが80枚、実際には日光角化症であるものが1枚、皮角日光角化症であるものが4枚、ポーエン病であるものが4枚、基底細胞癌であるものが5枚、無色素基底細胞癌であるものが5枚、悪性メラノ

ーマであるものが1枚、無色素悪性メラノーマであるものが1枚、汗孔腫であるものが4枚、無色素汗孔腫であるものが3枚、脂漏性角化症であるものが1枚であった。即ち有棘細胞癌と判定された画像のうち実際の疾患が有棘細胞癌であるもの（陽性的中率：Precision）は73%であった。

[0085] （24クラス分類TOP3正答率）

24クラスの疾患の判定において、分類器が可能性の高い皮膚腫瘍の種類を上位3つまで判定する。このとき、分類器が判定した3つの種類のいずれかに正答があった場合を24クラス分類TOP3正答と定義した場合の判定結果（正答率）は、モデル1では91%、モデル2では89%であった。

[0086] （2クラス分類TOP3正答率）

24クラスの疾患の判定において、分類器が可能性の高い皮膚腫瘍の種類を上位3つまで判定する。このとき、実際の腫瘍が悪性であり、一方分類器の示した3つの種類のいずれかに悪性腫瘍があった場合に悪性判定の正解とする。また、実際の腫瘍が良性であり、一方、分類器の示した3つの種類のいずれも良性腫瘍であった場合に良性判定の正解とする。これを2クラス分類TOP3正答と定義した場合の判定結果（正答率）は、モデル1では99%、モデル2では98%であった。

[0087] （2クラス分類感度）

24クラスの疾患の判定において、分類器が最も可能性の高い皮膚腫瘍の種類を判定する。分類器が最も可能性が高いと判定した皮膚腫瘍について、良性か悪性かを判定した場合に、判定結果の感度（Recall）は、モデル1においては悪性が94%、良性が79%、またモデル2においては悪性が94%、良性が83%であった。

## 実施例 2

[0088] 分類器として、ImageNetで学習した重みをもつ公知の画像分類モデルの中から2種を選択して、それぞれ教師画像（前記24クラスから乳房外パジェット病、血管肉腫、化膿性肉芽腫の3クラスを除いた21クラスの皮膚腫瘍の画像）を合計7011枚用いて学習させた。

学習機の性能は、画像を10分割し、9/10を教師画像、1/10をテスト画像とし、交差検証法を用いて評価した。

[0089] 本実施例によれば、全体の正答率はモデル1で70%、モデル2で74%であった。個々の判定結果を例示すると、モデル2において、悪性メラノーマの画像72枚について、分類器が、悪性メラノーマと正しく判定したものが64枚、有棘細胞癌と判定したものが1枚、基底細胞癌と判定したものが4枚、無色素悪性メラノーマと判定したものが2枚、脂漏性角化症と判定したものが2枚であった。即ち、悪性メラノーマの画像について正しく悪性メラノーマと判定した割合（感度：Recall）は83%であった。

[0090] 一方、分類器が悪性メラノーマと判定した86枚の患部画像のうち、実際の疾患が悪性メラノーマであるものが64枚、実際の疾患が日光角化症であるものが1枚、有棘細胞癌であるものが2枚、基底細胞癌であるものが3枚、無色素悪性メラノーマであるものが1枚、無色素汗孔腫であるものが3枚、脂漏性角化症であるものが3枚、青色母斑であるものが4枚、先天性色素性母斑であるものが2枚、母斑細胞母斑であるものが2枚、スピッツ母斑であるものが2枚であった。即ち、悪性メラノーマと判定された画像のうち実際の疾患が悪性メラノーマであるもの（陽性的中率：Precision）は74%であった。

[0091] （21クラス分類TOP3正答率）

21クラスの疾患の判定において、分類器が可能性の高い皮膚腫瘍の種類を上位3つまで判定する。このとき、分類器が判定した3つの種類のいずれかに正答があった場合を21クラ分類TOP3正答と定義した場合の判定結果（正答率）は、モデル1では93%、モデル2では93%であった。

[0092] （2クラス分類TOP3正答率）

21クラスの疾患の判定において、分類器が可能性の高い皮膚腫瘍の種類を上位3つまで判定する。このとき、実際の腫瘍が悪性であり、一方分類器の示した3つの種類のいずれかに悪性腫瘍があった場合に悪性判定の正解とする。また、実際の腫瘍が良性であり、一方、分類器の示した3つの種類の

いずれも良性腫瘍であった場合に良性判定の正解とする。これを2クラス分類TOP3正答と定義した場合の判定結果（正答率）は、モデル1では99%、モデル2では98%であった。

[0093] (2クラス分類感度)

21クラスの疾患の判定において、分類器が最も可能性の高い皮膚腫瘍の種類を判定する。分類器が最も可能性が高いと判定した皮膚腫瘍について、良性か悪性かを判定した場合に、判定結果の感度（Recall）は、モデル1においては悪性が98%、良性が84%、またモデル2においては悪性が97%、良性が88%であった。

### 実施例 3

[0094] 除外判定器（第1ステップ）のモデル実験1：

例えば、深層ニューラルネットを特徴抽出器として活用し、その特徴を用いて除外判定を行う等の手順で除外判定器（除外判定用モデル）を作成した。

皮膚腫瘍ではない画像6枚を、除外判定器に入力した。

その結果6枚（自動車、猫、地球、腕、犬、船）はいずれも皮膚腫瘍ではないとして除外判定された。

この時、皮膚腫瘍の画像の約5%が皮膚腫瘍ではないと除外判定された。

また、皮膚腫瘍ではないと除外判定された6枚をモデル1の分類器に入力すると、最も確からしいと判定した疾患は6枚とも悪性メラノーマであった。これは、全く皮膚腫瘍とは関係ない画像であっても、分類器は皮膚腫瘍のいずれかのクラスに判定することを示している。

### 実施例 4

[0095] 除外判定器（第1ステップ）のモデル実験2：

分類器として、ImageNetで学習した重みをもつ公知の画像分類モデルの中から1種を選択して、教師画像（前記実施例2と同じ21クラスの皮膚腫瘍の画像を合計7011枚と、炎症性皮膚疾患であるアトピー性皮膚炎、乾癬、菌状息肉症の3クラスの合計1044枚とを用いて学習させた。

学習は、画像を10分割し、9/10を教師画像、1/10をテスト画像とし、汎化精度をテストデータで算出した。

テスト画像としては、皮膚腫瘍の画像を691枚、炎症性皮膚疾患の画像を74枚用いた。この結果、皮膚腫瘍の画像を分類器が皮膚腫瘍と判定したものが689枚、皮膚腫瘍の画像を分類器が炎症性皮膚疾患と判定したものが2枚であった。また、炎症性皮膚疾患の画像を分類器が炎症性皮膚疾患と判定したものが66枚、炎症性皮膚疾患の画像を分類器が皮膚腫瘍と判定したものが8枚であった。即ち、皮膚腫瘍の観点では、感度 (Recall) が99.7%、陽性的中率 (Precision) は98.9%であった。

これにより、皮膚疾患の画像を入力した場合、皮膚腫瘍であるか、炎症性皮膚疾患であるかが区別できる。従って、この除外判定器によれば、なんらかの皮膚疾患であることが確実な画像を入力することにより、炎症性皮膚疾患を除外し、皮膚腫瘍のみ判定し、次の第2ステップに用いることが可能となる。

## 実施例 5

[0096] 除外判定器 (第1ステップ) のモデル実験3 :

分類器として、ImageNetで学習した重みをもつ公知の画像分類モデルの中から1種を選択した。また、皮膚腫瘍の画像としては、前記実施例2と同じ21クラスの皮膚腫瘍の画像を、合計7011枚を用いた。また、皮膚腫瘍以外の画像としては、Google Open Image V4の確認データからランダムに選択した7000枚を用いた。このうち皮膚腫瘍の画像3476枚と皮膚腫瘍以外の画像3500枚を教師データとして用いて深層学習により学習させた。

一方残りの皮膚腫瘍の画像3575枚と皮膚腫瘍以外の画像3500枚について、学習済みモデルにより皮膚腫瘍であるか皮膚腫瘍以外であるかを判定した。

その結果、皮膚腫瘍画像3575枚のうち、皮膚腫瘍と判定したものが3567枚であり、皮膚腫瘍以外と判定したものが8枚であった。また、皮膚

腫瘍以外の画像3500枚のうち、皮膚腫瘍と判定したものが19枚、皮膚腫瘍以外と判定したものが3481枚であった。

即ち、皮膚腫瘍の観点では、感度は99.8%であり、特異度は99.5%であり、陽性的中率は99.8%であり、陰性的中率は99.5%であり、正答率は99.6%であった。

この除外判定器のモデルにより、送付間違い等により皮膚腫瘍以外の画像が分類器に送られた場合でも、皮膚腫瘍以外であることを検知し使用者にその旨伝達することができ、誤判定を回避することが可能となる。

## 実施例 6

[0097] 本実施例では、分類器として、ImageNetで学習した重みをもつ公知の画像分類モデルの中から1種を選択した。教師画像及びテスト画像としては、実施例1と同様に、上記の24クラスの皮膚腫瘍の画像を、合計7532枚を用いた。

学習機の性能は、画像を10分割し、9/10を教師画像として学習させ、1/10をテスト画像とし、交差検証法を用いて評価した。この交差検証を3回行なった結果、テスト画像として判定されたものは3回合わせて2247枚となった。この判定結果を図9に示す。

これによると、2247枚の画像のうち、疾患毎にその疾患として正しく判定された的中率は70%であった。またその疾患が悪性であるか良性であるかについて正しく判定された的中率は89%であった。

[0098] 臨床的には悪性腫瘍を良性と誤判定しないようにすることが求められるが、悪性腫瘍を良性腫瘍と誤判定する場合にも特徴的な傾向がみられる。図9及び図29に示された判定結果をみると、基底細胞癌(BCC)、悪性メラノーマ(MM)、脂漏性角化症(SK)、及び母斑細胞母斑(NCN)の4クラスが互いに誤判定している例数が多いことが判る。また、悪性メラノーマ(MM)は、上記の3クラスの外、良性の無色素汗孔腫(Poroma)と誤判定される場合も多いことが判る。このように24クラス判定において誤判定し易い腫瘍と判定された場合に、再度互いに誤判定されやす

い腫瘍クラスに絞った分類器を用いて再判定することが好ましい。

## 実施例 7

[0099] そこで、次に、図9及び後述の図29に示されている通り、互いに誤判定されやすい基底細胞癌、悪性メラノーマ、脂漏性角化症、及び母斑細胞母斑の4つの腫瘍を示す画像のみを用いてモデルを学習させて分類器を作成した(第2学習済みモデルの一例)。ここで用いた分類器は、ImageNetで学習した重みをもつ公知の画像分類モデルの中から1種を選択した。また、用いた画像は、基底細胞癌1100枚、悪性メラノーマ625枚、脂漏性角化症520枚、母斑細胞母斑1165枚であった。

前記の4腫瘍クラスの画像(基底細胞癌1100枚、悪性メラノーマ625枚、脂漏性角化症520枚、母斑細胞母斑1165枚)について10分割し、9/10を教師画像、1/10をテスト画像とし、交差検証法を用いて評価した。この評価を10回行い、そのなかで最も平均的な判定を行った結果を図10に示す。

また、悪性(基底細胞癌及び悪性メラノーマ)と良性(脂漏性角化症及び母斑細胞母斑)としての判定結果を図11に示す。

## 実施例 8

[0100] 前記の4腫瘍クラスの画像について10分割し、9/10を教師画像、1/10をテスト画像とし、交差検証法を用いて評価した。但し、本実施例においては、基底細胞癌及び悪性メラノーマを示す画像について、他の疾患と類似しているもの(例えば、24クラス判定で他の疾患クラスと判定されたもの及びそれと同じ症例のもの)を抽出して基底細胞癌の画像を292枚、悪性メラノーマの画像を149枚選択した。

[0101] これらの画像については、コントラストを変化させる、ノイズを加えるなどの加工を施すことにより10倍に増加させた。これにより本実施例に用いた基底細胞癌の画像は10倍に増加させた分が2910枚、処理を行わなかった分が808枚、計3718枚であった。また、本実施例に用いた悪性メラノーマの画像は、10倍に増加させた分が1490枚、処理を行わなかつ

た分が456枚、計1946枚であった。なお、悪性メラノーマ（悪性黒色腫）において母斑細胞母斑と形状が類似している患部の画像については、少なくとも2倍以上に数を増やす処理を行うことが好ましく、5倍以上に数を増やす処理を行うことが更に好ましい。また、悪性メラノーマ（悪性黒色腫）及び／又は基底細胞癌において他の疾患と形状が類似している患部の画像については、少なくとも2倍以上に数を増やす処理を行うことが好ましく、5倍以上に数を増やす処理を行うことが更に好ましい。

[0102] また、本実施例に用いた脂漏性角化症の画像は520枚、母斑細胞母斑の画像は1165枚であった。

この評価を10回交差検証法により10回行い、そのなかで最も平均的な判定を行った評価の結果を図12に示す。

また、悪性（基底細胞癌及び悪性メラノーマ）と良性（脂漏性角化症及び母斑細胞母斑）としての判定結果を図13に示す。

この結果、実施例7（図10及び図11）と実施例8（図12と図13）とを比較すると、実施例8の方が高い正解率が得られた。実施例8においては他の疾患クラスと間違いやすい画像について枚数を増やしたことにより、他の疾患クラスと間違いやすい画像を多く学習した結果、画像的に類似のものをより正確に判定できるようになったものと考えられる。

## 実施例 9

[0103] 本実施例では、実施例6で用いた24クラス分類器によって判定した結果が、基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であった画像について、実施例8で用いた4クラス分類器により再判定した場合の結果をシミュレーションしたものである。

手順は、以下の通り。

実施例6で用いた画像のうち、実際の診断結果が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であった画像について、実施例6による24クラス分類器の出力結果が、基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であったもの（正解、不正解のいずれも）を抽

出する。

抽出された画像のうち、実施例8に用いられた画像を抽出する。即ち、両方に用いられた画像を抽出する。

そして、抽出された各画像について、まず、24クラス分類器により、その出力結果が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であるかを判定し、次に、4クラス分類器（実施例8で用いたもの）により再判定した結果を得る。

結果を図14に示す。また、悪性（基底細胞癌及び悪性メラノーマ）と良性（脂漏性角化症及び母斑細胞母斑）としての判定結果を図15に示す。

### 実施例 10

[0104] 本実施例では、実施例6で用いた24クラス分類器によって判定した結果が、脂漏性角化症、または母斑細胞母斑であった画像について、実施例8で用いた4クラス分類器により再判定した場合の結果をシミュレーションしたものである。

手順は、以下の通り。

実施例6で用いた画像のうち、実際の診断結果が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であった画像について、実施例6による24クラス分類器の出力結果が、基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であったもの（正解、不正解のいずれも）を抽出する。

抽出された画像のうち、実施例8に用いられた画像を抽出する。即ち、両方に用いられた画像を抽出する。

そして、抽出された各画像について、まず、24クラス分類器により、その出力結果が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であるかを判定し、次に、その出力結果が脂漏性角化症または母斑細胞母斑であったものについて4クラス分類器（実施例8で用いたもの）により再判定した結果を得る。なお、この時24クラス分類器により基底細胞癌または悪性メラノーマと判定された画像については、その結果を保持し、4クラ

ス分類器による再判定は行わない。

結果を図16に示す。また、悪性（基底細胞癌及び悪性メラノーマ）と良性（脂漏性角化症及び母斑細胞母斑）としての判定結果を図17に示す。

図17に示した通り、特定の悪性腫瘍と誤判定しやすい良性腫瘍に対して再判定を行うことにより、良性を悪性と誤判定する例は若干増加するが、悪性を良性と誤判定することが少なくなり、悪性腫瘍を見逃さないという観点から有用である。

### 参考例1

[0105] 24クラス分類器により各種腫瘍クラスの画像を判定した結果、その出力が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑となるものは、実際の診断結果が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑以外のものも含まれる（図9及び図29参照）。

そこで、本参考例は、24クラス分類器によりその出力が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑となったものの内、実際の診断結果がこれら4つの腫瘍クラスではないものについて、4クラス判定器により再判定した結果をシミュレーションしたものである。

実施例6で用いた画像のうち、実際の診断結果が基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑以外であった画像について、実施例6による24クラス分類器の出力結果が、基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑であったもの（この場合はいずれも不正解である）を抽出する。

抽出された画像のうち、実施例8に用いられた画像を抽出する。即ち、両方に用いられた画像を抽出する。

そして、抽出された各画像について、まず、24クラス分類器により、その出力結果が基底細胞癌または悪性メラノーマ（悪性の腫瘍）であるか、脂漏性角化症または母斑細胞母斑（良性の腫瘍）であるかを判定する。その結果、悪性、良性の判定について図18に示す。

次に、抽出された各画像について、4クラス分類器（実施例8で用いたもの

)により再判定した結果を得た。その結果、悪性、良性の判定について図19に示す。

## 参考例2

[0106] 本参考例は、24クラス分類器によりその出力が、脂漏性角化症、または母斑細胞母斑となったものの内、実際の診断結果がこれら基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑の4つの腫瘍クラスではないものについて、4クラス判定器により再判定した結果をシミュレーションしたものである。

実施例6で用いた画像のうち、実際の診断結果が、基底細胞癌、悪性メラノーマ、脂漏性角化症、または母斑細胞母斑以外であった画像について、実施例6による24クラス分類器の出力結果が、脂漏性角化症、または母斑細胞母斑であったもの（この場合はいずれも不正解である）を抽出する。抽出された画像のうち、実施例8に用いられた画像を抽出する。即ち、両方に用いられた画像を抽出する。

そして、抽出された各画像について、まず、24クラス分類器により、その出力結果が基底細胞癌または悪性メラノーマ（悪性腫瘍）であるか、脂漏性角化症または母斑細胞母斑（良性腫瘍）であるかを判定する。次に、判定結果が脂漏性角化症または母斑細胞母斑であるものについて、4クラス分類器（実施例8で用いたもの）により再判定した結果を得る。その結果、悪性、良性を図20に示す。

参考例1及び参考例2の結果、特定の4クラスに属さない種類の腫瘍について、4クラス分類器を用いた場合でも正解率はほぼ変わらず、従って、4クラス分類器を4クラス以外の腫瘍に用いたとしてもこれによる悪影響はないものと考えられる。

## 実施例11

[0107] 本実施例では、1つの症例について複数枚の写真を撮影し、それらの画像を24クラス分類器に用いた場合の複数枚判定の効果を確認するものである。

実施例6で用いた画像の中には、1つの症例について複数の画像を有するものがある。同じ症例について複数の画像すべてが同じ判定結果を示すこともあるが、判定結果が異なることもある。図21には、悪性メラノーマと診断された症例について複数の画像データを有し、且つ判定結果（A1判定第一候補）が異なる3例が示されている。

実施例6で用いられた24クラス分類器は、判定を行うと、24クラスの腫瘍についてそれぞれ分類器が判断した確からしさ（確信度）を足して1になるような数値で出力される。図21には、確信度の大きい上位2つの腫瘍が示されている。通常、確信度の最も高い腫瘍を分類器の判定結果としている。

[0108] 図21を見ると、確信度は同じ症例であっても異なることがあり、さらには最も大きい確信度を有する腫瘍（即ち判定結果）が異なる場合がある。

一方、実施例6において、得られた判定結果をみると、その時の確信度（図21においては確信度1にあたる）により、正解率が異なることが分かった。即ち、図22に示すように、確信度が大きいほうが、正解率が高いという結果が得られた。このことは、1症例について、複数枚の画像を判定し、それぞれ判定した後に、確信度の最も大きいものを採用することにより正解率が向上できることを示唆している。

[0109] 図23には、悪性メラノーマ（MM）及び母斑細胞母斑（NCN）について、実施例6で同じ症例について複数枚の画像が判定された例を示す。

「複数枚全正解」とは、同じ症例について複数枚の画像を判定したところ全て正解であったもの（例えば診断結果がMMであった場合に、A1による判定結果がすべてMMであったもの）である。

「複数枚全不正解」とは、同じ症例について複数枚の画像を判定したところ全て不正解であったものである。

「確信度最大を選択すると正解」とは、同じ症例について複数枚の画像を判定したところ正解と不正解が混在し、その中で最も確信度の高いものを選択した場合にそれが正解であったものである。

「確信度最大を選択すると不正解」とは、同じ症例について複数枚の画像を判定したところ、正解と不正解が混在し、その中で最も確信度の高いものを選択した場合にそれが不正解であったものである。

- [0110] 本実施例では、分類器として、ImageNetで学習した重みをもつ公知の画像分類モデルのなかから1種を選択した。教師画像およびテスト画像としては、実施例1と同様に、上記の24クラスの皮膚腫瘍の画像を、合計7532枚を用いた、  
図23に示す通り、悪性メラノーマ、母斑細胞母斑のいずれの場合も、「確信度最大を選択すると正解」の方が、「確信度最大を選択すると不正解」よりもかなり多く、即ち、複数枚撮影により正解率の向上が見込めることが示された。

## 実施例 12

- [0111] 本実施例では、分類器として、ImageNetで学習した重みをもつ公知の画像分類モデル10種（ResNet50、DenseNet169、DenseNet201、InceptionResNetV2、VGG16、VGG19、MobileNet、DenseNet121、Xception、InceptionV3）について、それぞれ教師画像（上記の24クラスの皮膚腫瘍の画像を、合計7532枚）を用いて学習とテストを行った。画像の約90%を学習データ、約10%をテストデータとし使い、学習データの判定及びテストデータの判定を行った。モデルの学習は、学習データの正解が多くなるように再学習を行うが、テストデータの正解率が上昇しなくなるまで再学習を繰り返した。再学習を終了した時点までの学習曲線を図24及び図25に示す。図24及び図25において、縦軸は正解率を、横軸は再学習の回数を示している。

- [0112] また、再学習を終了した時点において最もテストデータの正解率が高いものについての正解率を図26に示す。ここでは3回のテストを行い、24クラス判定及び良性／悪性判定について、正解率の平均と標準偏差を示す。いずれの学習済みモデルにおいても一定の良好な正解率が得られることがわか

る。

また、モデルとして DenseNet 201 を用いた場合のテストデータの混同行列の一例を図 27 に示す。この場合、テストデータとして 752 個を用いた。

悪性と良性とを判別する観点からは、全体の正解率が 89%、悪性腫瘍の正解率が 94%、良性腫瘍の正解率が 83% であった。

[0113] 図 27 において、recall 17Class は、24 クラスを 17 クラスに纏めた場合の正解率である。例えば、BCC (基底細胞癌) と BCCameia (無色素基底細胞癌) を同じクラスにしている。従って、診断結果が BCC であれば、本発明によるシステムの推測結果が BCC 又は BCCameia の場合に正解となる。

また、図 27 において、recall 6Class は、24 クラスを 6 クラスに纏めたものである。例えば、AK、AKhorn、bowen、SCC、BCC、BCCameia、EMPD (これらは悪性の上皮細胞系細胞の腫瘍に分類される) を同じクラスにしている。従って、診断結果が AK であれば、本発明によるシステムの推定結果が AK、AKhorn、bowen、SCC、BCC、BCCameia、または EMPD の場合に正解となる。

[0114] これらモデルを実装するにあたっては、錯誤する腫瘍の傾向や、過学習の起こしやすさ、どの様な判定結果を出力するかなどを考慮して最適なモデルを適宜選択することができる。

### 実施例 13

[0115] 本実施例では、分類器として、ImageNet で学習した重みをもつ公知の画像分類モデルの中から 1 種を選択した。教師画像及びテスト画像としては、実施例 1 と同様に、上記の 24 クラスの皮膚腫瘍の画像を、合計 7532 枚を用いた。

学習機の性能は、各回に画像の概ね 1/10 をランダムに抽出してテスト画像とし、残りの概ね 9/10 を学習画像として学習させ、交差検証法を用

いて評価した。この交差検証を10回行なった結果、テスト画像として判定されたものは10回合わせて7472枚となった。この判定結果を図29に示す。

悪性と良性とを予測する観点では、全体の正解率は90.0%、悪性腫瘍の正解率は92.7%、良性腫瘍の正解率は85.8%であった。

#### 実施例 14

[0116] 実施例13の24クラス判定において汗孔腫 (Poromameia) と判定されたものは48枚であった。これを実施例8で用いた4クラス判定器 (BCC, MM, SK, NCNのいずれであるかを判定するもの) で再判定を行った。その結果を図30に示す。Poromameiaと判定されたもののうち17枚は悪性腫瘍であったが、このうち15枚は4クラス再判定により悪性と判定 (正解) された。一方、良性と判定されたもの31枚のうち、4クラス再判定により14枚が悪性と判定 (不正解) された。4クラス再判定による全体の正解率は67%であり、24クラス判定 (65%) とほぼ変わらなかった。このことから、悪性を見逃さないという観点から、特定の腫瘍クラス再判定は効果があると考えられる。

#### 実施例 15

[0117] 本実施例では、分類器として、除外判定エンジン (第1ステップ)、24クラス判定器 (第2ステップ)、4クラス再判定器 (第3ステップ) の3つを実装し、1症例につき、最大4枚の画像を用いて判定したものである。

利用者クライアント端末としては、iPod (登録商標) touch MVHW2J/Aを用いた。クライアント端末は、ユーザのログイン認証を行ってログインし、Webブラウザから呼び出されたiPod touchのカメラ機能を用いて写真を最大4枚撮影し、撮影時に腫瘍が写真の中央部に配置されるようにガイド枠が設けられ (患部切り出し)、撮影された写真をサーバーに送る、の各機能を有するアプリケーションが搭載されている。ブラウザはGoogle Chromeを用いた。サーバーへの写真の送信など、クライアント端末とサーバーとの通信はwifiを用いた。

また、サーバーは次に示すスペックのものを用いた。CPU: Intel (登録商標) Core i7-8700K, 3.70GHz、GPU: GeForce GTX 1080 Ti、メモリ: 32GB。

[0118] サーバーは、まずアプリサーバーがクライアント端末から送られた写真を受け取り、AIサーバーで各写真について、(1) 腫瘍画像かどうかを判定する(除外判定)学習済みモデル、(2) 24疾患クラスのいずれかを判定する学習済みモデル、(3) BCC, MM, SK, NCCの4疾患クラスのいずれかを判定する学習済みモデルにより、それぞれ判定する。なお、判定に際して判定結果は、どの疾患クラスに該当するかについて疾患クラスの名称と確信度(合計が1となる)で示される。また、暗号化した写真及び判定結果はファイルサーバーに保存される。

[0119] 判定結果は管理者クライアント端末から参照することができる。

前記クライアント端末とサーバーを用いて患部の写真を撮影し、判定を行ったところ、4枚の写真を送信してから判定が完了するまでの時間は概ね60~120秒であった。

前記クライアント端末を用いて撮影した写真のうち、医師による診断がBCCであったもの6症例について以下の手順で判定を行った。

(1) それぞれの症例につきユーザ端末で4枚の写真を撮り、サーバーに送り、3つの分類器を実行した。

(2) 除外判定エンジンにより、皮膚腫瘍ではないと判定された画像については、判定の候補から外した。なお図31中、除外された画像が1枚(症例番号6、写真番号1)あるが、これは、画像全体が光っており、腫瘍が不鮮明となっていた。そのため、皮膚腫瘍と認識されなかったものと思われる。

(3) 24クラス判定を行い、その結果がSK又はNCCであった画像は、4クラス再判定を行った。

(4) 24クラス判定において、確信度が最も高いものを、その症例の本システムの判定結果とした。なお、確信度が最も高いものがSK又はNCC

であった場合には4クラス再判定の結果が本システムの判定結果となるが、今回の6症例ではそのケースはなかった。

結果を図31に示す。この実施例が示すように、いくつかの分類器を同時に使用し、悪性腫瘍を見逃さないようなシステムを構築することができる。

[0120] [ソフトウェアによる実現]

図4に示した各処理は、集積回路（ICチップ）等に形成された論理回路（ハードウェア）によって実現してもよいし、CPU（Central Processing Unit）を用いてソフトウェアによって実現してもよい。

[0121] 図4に示した各処理ソフトウェアによって実現する場合、利用者クライアント端末100、皮膚疾患解析装置200及び管理者クライアント端末300は、各機能を実現するソフトウェアであるプログラムの命令を実行するCPU、上記プログラム及び各種データがコンピュータ（又はCPU）で読み取り可能に記録されたROM（Read Only Memory）又は記憶装置（これらを「記録媒体」と称する）、上記プログラムを展開するRAM（Random Access Memory）などを備えている。そして、コンピュータ（又はCPU）が上記プログラムを上記記録媒体から読み取って実行することにより、本発明の目的が達成される。上記記録媒体としては、「一時的でない有形の媒体」、例えば、テープ、ディスク、カード、半導体メモリ、プログラマブルな論理回路などを用いることができる。また、上記プログラムは、該プログラムを伝送可能な任意の伝送媒体（通信ネットワークや放送波等）を介して上記コンピュータに供給されてもよい。なお、本発明の一態様は、上記プログラムが電子的な伝送によって具現化された、搬送波に埋め込まれたデータ信号の形態でも実現され得る。

[0122] 本発明は上述した実施形態に限定されるものではなく、開示した範囲で種々の変更が可能であり、異なる実施形態にそれぞれ開示された技術的手段を適宜組み合わせて得られる実施形態についても本発明の技術的範囲に含まれる。

[0123] 本出願は、2019年3月29日に出願された日本特許出願である特願2019-067229号、及び2019年11月15日に出願された日本特許出願である特願2019-206765号に基づく優先権を主張し、当該日本特許出願に記載されたすべての記載内容を援用する。

### 符号の説明

[0124] 1…皮膚疾患解析システム、2…ネットワーク、100…利用者クライアント端末、200…皮膚疾患解析装置、300…管理者クライアント端末。

## 請求の範囲

### [請求項1]

コンピュータにより実行される皮膚疾患解析プログラムであって、  
前記コンピュータに、

皮膚腫瘍の画像である解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた第1学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、

第1ステップ又は第3ステップのいずれか、あるいは両方を実行させ、

前記第1ステップは、前記第2ステップに先立って、皮膚疾患判定エンジンにより、解析対象画像が皮膚腫瘍の画像であるか否かを判定するステップであり、

前記第3ステップは、前記第2ステップの判定結果が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより、解析対象画像に対して皮膚腫瘍の種類を再予測するステップである、

ことを特徴とする皮膚疾患解析プログラム。

### [請求項2]

コンピュータにより実行される皮膚疾患解析プログラムであって、  
前記コンピュータに、

皮膚疾患判定エンジンにより、解析対象画像が皮膚腫瘍の画像であるか否かを判定する第1ステップと、

前記第1ステップによって前記解析対象画像が皮膚腫瘍の画像であると判定された場合、該解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、

を実行させる、

ことを特徴とする皮膚疾患解析プログラム。

### [請求項3]

コンピュータにより実行される皮膚疾患解析プログラムであって、

前記コンピュータに、

皮膚腫瘍の画像である解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた第1学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、

前記第2ステップの判定結果が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより、解析対象画像に対して皮膚腫瘍の種類を再予測する第3ステップと、

を実行させる、

ことを特徴とする皮膚疾患解析プログラム。

[請求項4]

前記第2ステップは、予め4～50種類の皮膚腫瘍の患部の画像によって機械学習させた第1学習済みモデルにより皮膚腫瘍の種類を予測するものである、

ことを特徴とする請求項1～3のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項5]

前記第2ステップは、皮膚疾患としては、少なくとも悪性黒色腫を含む3種またはそれ以上の患部の画像によって機械学習させた第1学習済みモデルにより解析対象画像の皮膚腫瘍の種類を予測するものであり、

前記第3ステップは、前記第2ステップによって前記解析対象画像が悪性黒色腫と誤判定されやすい腫瘍であると予測された場合、該解析対象画像に対し、予め悪性黒色腫及び当該悪性黒色腫と誤判定されやすい腫瘍を含む皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより皮膚腫瘍の種類を再予測する、

ことを特徴とする請求項1又は3に記載の皮膚疾患解析プログラム。

[請求項6]

前記悪性黒色腫と誤判定されやすい腫瘍として少なくとも母斑細胞母斑を含み、

前記第2ステップは、皮膚疾患として、少なくとも悪性黒色腫及び母斑細胞母斑を含む3種またはそれ以上の患部の画像によって機械学習させた第1学習済みモデルにより解析対象画像の皮膚腫瘍の種類を予測し、

前記第3ステップは、前記第2ステップによって前記解析対象画像が母斑細胞母斑であると判定された場合、該解析対象画像に対し、予め少なくとも悪性黒色腫及び母斑細胞母斑を含む皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより皮膚腫瘍の種類を再予測する、

ことを特徴とする請求項1又は3に記載の皮膚疾患解析プログラム。

[請求項7]

前記第2ステップは、皮膚疾患として、少なくとも悪性黒色腫、基底細胞癌、脂漏性角化症及び母斑細胞母斑を含む5種またはそれ以上である皮膚疾患の患部の画像により機械学習させた前記第1学習済みモデルにより解析対象画像の皮膚腫瘍の種類を予測し、

前記第3ステップは、前記第2ステップによって前記解析対象画像が母斑細胞母斑又は脂漏性角化症と判定された場合、該解析対象画像に対し、予め少なくとも悪性黒色腫、基底細胞癌、脂漏性角化症及び母斑細胞母斑を含む皮膚疾患の患部の画像により機械学習させた前記第2学習済みモデルにより皮膚腫瘍の種類を再予測する、

ことを特徴とする請求項1又は3に記載の皮膚疾患解析プログラム。

[請求項8]

前記第2ステップは、皮膚疾患として、少なくとも悪性黒色腫、基底細胞癌、脂漏性角化症及び母斑細胞母斑を含む5種またはそれ以上である皮膚疾患の患部の画像により機械学習させた前記第1学習済みモデルにより解析対象画像の皮膚腫瘍の種類を予測し、

前記第3ステップは、前記第2ステップによって前記解析対象画像が悪性黒色腫、基底細胞癌、母斑細胞母斑又は脂漏性角化症と判定された場合、該解析対象画像に対し、予め少なくとも悪性黒色腫、基底細胞癌、脂漏性角化症及び母斑細胞母斑を含む皮膚疾患の患部の画像

により機械学習させた前記第2学習済みモデルにより皮膚腫瘍の種類を再予測する、

ことを特徴とする請求項1又は3に記載の皮膚疾患解析プログラム。

[請求項9]

前記第2ステップは、少なくとも悪性黒色腫、基底細胞癌、脂漏性角化症及び母斑細胞母斑の4種を含み、更に、日光角化症、ポーエン病、有棘細胞癌、汗孔腫、脂腺母斑、青色母斑、先天性色素性母斑、スピッツ母斑、単純黒子、扁平母斑から選ばれる少なくとも1種以上を含んだ5種以上の皮膚腫瘍の中から皮膚腫瘍の種類を予測し、

前記第3ステップは、前記第2ステップによって前記解析対象画像が母斑細胞母斑または脂漏性角化症と判定された場合、該解析対象画像に対し、予め少なくとも悪性黒色腫を含む2種以上の皮膚疾患の患部の画像によって機械学習させた前記第2学習済みモデルにより皮膚腫瘍の種類を再予測する、

ことを特徴とする請求項1又は3に記載の皮膚疾患解析プログラム。

[請求項10]

前記第2ステップは、少なくとも悪性黒色腫、基底細胞癌、脂漏性角化症、母斑細胞母斑、及び無色素汗孔腫を含む5種またはそれ以上である皮膚疾患の患部の画像により機械学習させた第1学習済みモデルにより皮膚腫瘍の種類を予測し、

前記第3ステップは、前記第2ステップによって前記解析対象画像が無色素汗孔腫と判定された場合、該解析対象画像に対し、基底細胞癌、悪性黒色腫、母斑細胞母斑及び脂漏性角化症の患部の画像によって機械学習させた前記第2学習済みモデル、または、基底細胞癌、悪性黒色腫、母斑細胞母斑及び無色素汗孔腫の患部の画像によって機械学習させた前記第2学習済みモデル、により再予測する

ことを特徴とする請求項1又は3に記載の皮膚疾患解析プログラム。

[請求項11]

前記第3ステップは、患部の画像により機械学習させる場合に、悪性黒色腫及び／又は基底細胞癌において他の疾患と形状が類似している患部の画像については、少なくとも2倍以上に数を増やす処理を行

う、

ことを特徴とする請求項5～10のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項12] 前記コンピュータに、前記予測の結果を表示するステップを実行させる、

ことを特徴とする請求項1～11のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項13] 前記コンピュータに、

ユーザからの前記解析対象画像を受け付けるステップと、

前記ユーザのユーザ種別を管理するステップと、

をさらに実行させ、

前記予測結果を表示するステップは、前記ユーザ種別に応じて表示内容を異ならせる、

ことを特徴とする請求項12に記載の皮膚疾患解析プログラム。

[請求項14] 前記予測結果を表示するステップは、前記第2ステップ及び／又は前記第3ステップによって予測された皮膚腫瘍の種別により、予測された疾患名と対処方法を表示する、

ことを特徴とする請求項12または13に記載の皮膚疾患解析プログラム。

[請求項15] 前記解析対象画像が悪性皮膚腫瘍であるか良性皮膚腫瘍であるかの予測を行う、

ことを特徴とする請求項1～14のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項16] 同じ患部の複数の画像に対して予測を行うことを特徴とする請求項1～15のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項17] 前記第2ステップは、前記解析対象画像が日光角化症、ボーエン病、有棘細胞癌、基底細胞癌、悪性黒色腫の少なくとも1つであることを予測可能である、

ことを特徴とする請求項1～16のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項18] 前記第2ステップは、前記解析対象画像が汗孔腫、脂腺母斑、脂漏性角化症、青色母斑、先天性色素性母斑、母斑細胞母斑、スピッツ母斑、単純黒子、扁平母斑の少なくとも1つであることを予測可能である、

ことを特徴とする請求項1～16のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項19] 前記予測に患部情報を用い、

前記患部情報は、患者の年齢、患部の大きさ、患部の匂い、疾患の発生部位、患部の立体形状の少なくとも1つを含む、

ことを特徴とする請求項1～18のいずれか1項に記載の皮膚疾患解析プログラム。

[請求項20] 皮膚疾患判定エンジンにより、解析対象画像が皮膚腫瘍の画像であるか否かを判定する第1ステップと、

前記第1ステップによって前記解析対象画像が皮膚腫瘍の画像であると判定された場合、該解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、

を含む、

ことを特徴とする皮膚疾患解析方法。

[請求項21] 解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた学習済みモデルにより皮膚腫瘍の種類を予測する第2ステップと、

前記第2ステップの判定結果が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより、解析対象画像に対して皮膚腫瘍の種類を再予測する第3

ステップと、  
を含む  
ことを特徴とする皮膚疾患解析方法。

[請求項22]

皮膚疾患解析プログラムを記憶する記憶部と、  
前記皮膚疾患解析プログラムを実行することにより、前記皮膚疾患解析装置の動作を制御する制御部と、を備え、  
前記制御部は、  
皮膚疾患判定エンジンにより、解析対象画像が皮膚腫瘍の画像であるか否かを判定し、  
前記解析対象画像が皮膚腫瘍の画像であると判定された場合、該解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた学習済みモデルにより皮膚腫瘍の種類を予測する、  
ことを特徴とする皮膚疾患解析装置。

[請求項23]

皮膚疾患解析プログラムを記憶する記憶部と、  
前記皮膚疾患解析プログラムを実行することにより、前記皮膚疾患解析装置の動作を制御する制御部と、を備え、  
前記制御部は、  
解析対象画像に対し、予め各種皮膚疾患の患部の画像によって機械学習させた第1学習済みモデルにより皮膚腫瘍の種類を予測し、  
前記解析対象画像が、互いに誤判定されやすい皮膚腫瘍の1種であった場合に、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより、解析対象画像に対して皮膚腫瘍の種類を再予測する、  
ことを特徴とする皮膚疾患解析装置。

[請求項24]

皮膚疾患解析装置と、前記皮膚疾患解析装置に対し解析対象画像を送信可能な利用者クライアント端末と、前記皮膚疾患解析装置と前記利用者クライアント端末とを接続して情報を伝達するネットワークとを備え、

前記皮膚疾患解析装置は、予め各種皮膚疾患の患部の画像により機械学習させた学習済みモデルと、皮膚疾患と皮膚疾患以外とを判定する皮膚疾患判定エンジンと、を有し、

前記皮膚疾患解析装置は、前記皮膚疾患判定エンジンにより、前記解析対象画像が皮膚腫瘍の画像であるか否かを判定し、前記解析対象画像が皮膚腫瘍の画像であると判定された場合、該解析対象画像に対し、前記学習済みモデルにより皮膚腫瘍の種類を予測する、ことを特徴とする皮膚疾患解析システム。

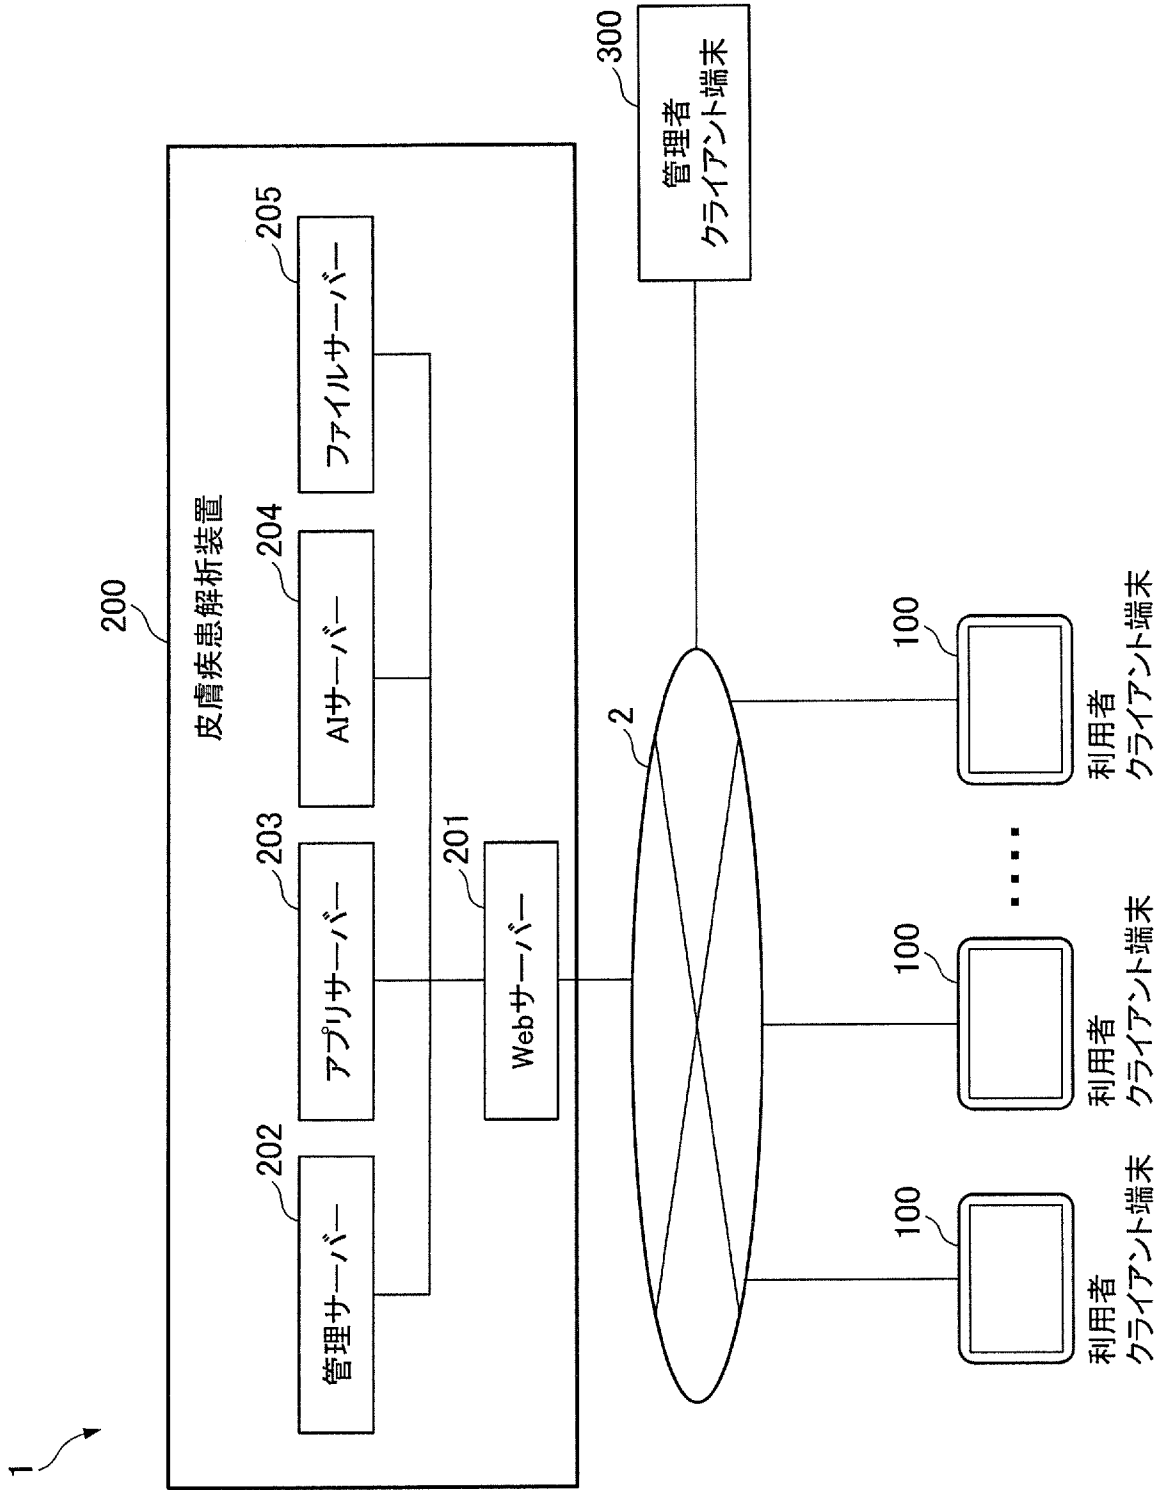
[請求項25]

皮膚疾患解析装置と、前記皮膚疾患解析装置に対し解析対象画像を送信可能な利用者クライアント端末と、前記皮膚疾患解析装置と前記利用者クライアント端末とを接続して情報を伝達するネットワークとを備え、

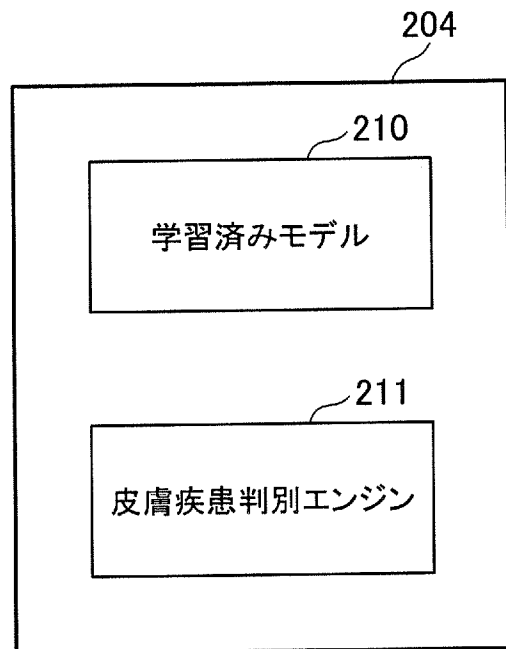
前記皮膚疾患解析装置は、予め各種皮膚疾患の患部の画像により機械学習させた第1学習済みモデルと、互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデル、とを有し、

前記皮膚疾患解析装置は、前記第1学習済みモデルにより前記解析対象画像が、互いに誤判定されやすい皮膚腫瘍の1種であると予測された場合、当該互いに誤判定されやすい皮膚腫瘍を含む特定の皮膚疾患の患部の画像によって機械学習させた第2学習済みモデルにより、解析対象画像に対して皮膚腫瘍の種類を再予測する、ことを特徴とする皮膚疾患解析システム。

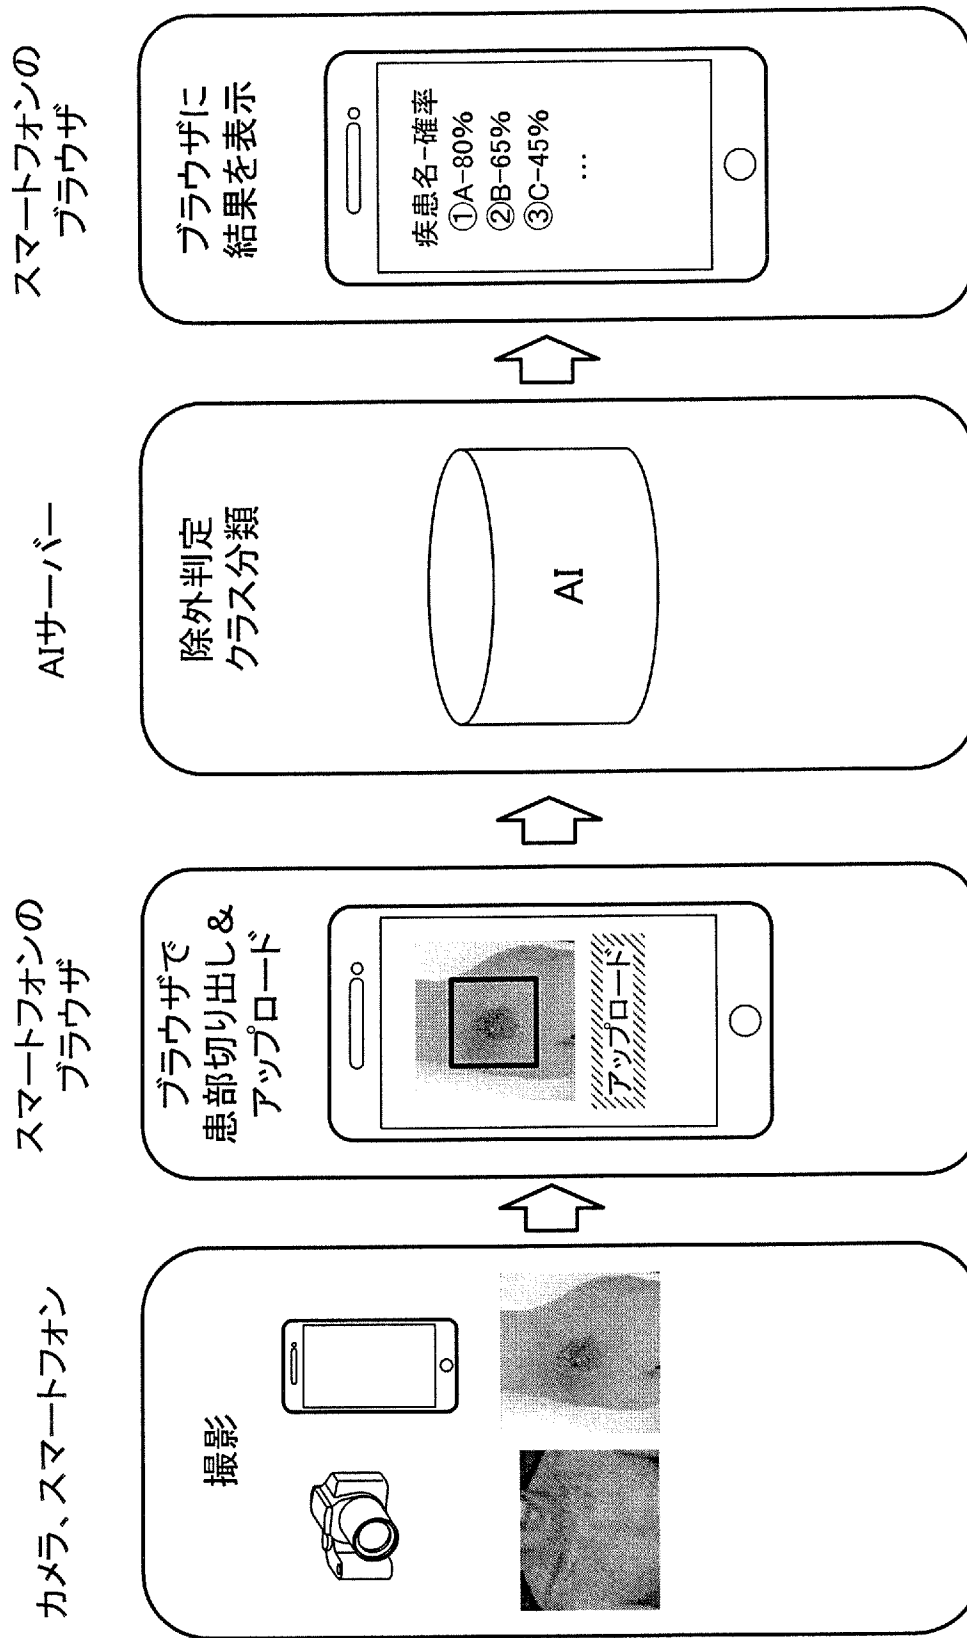
[図1]



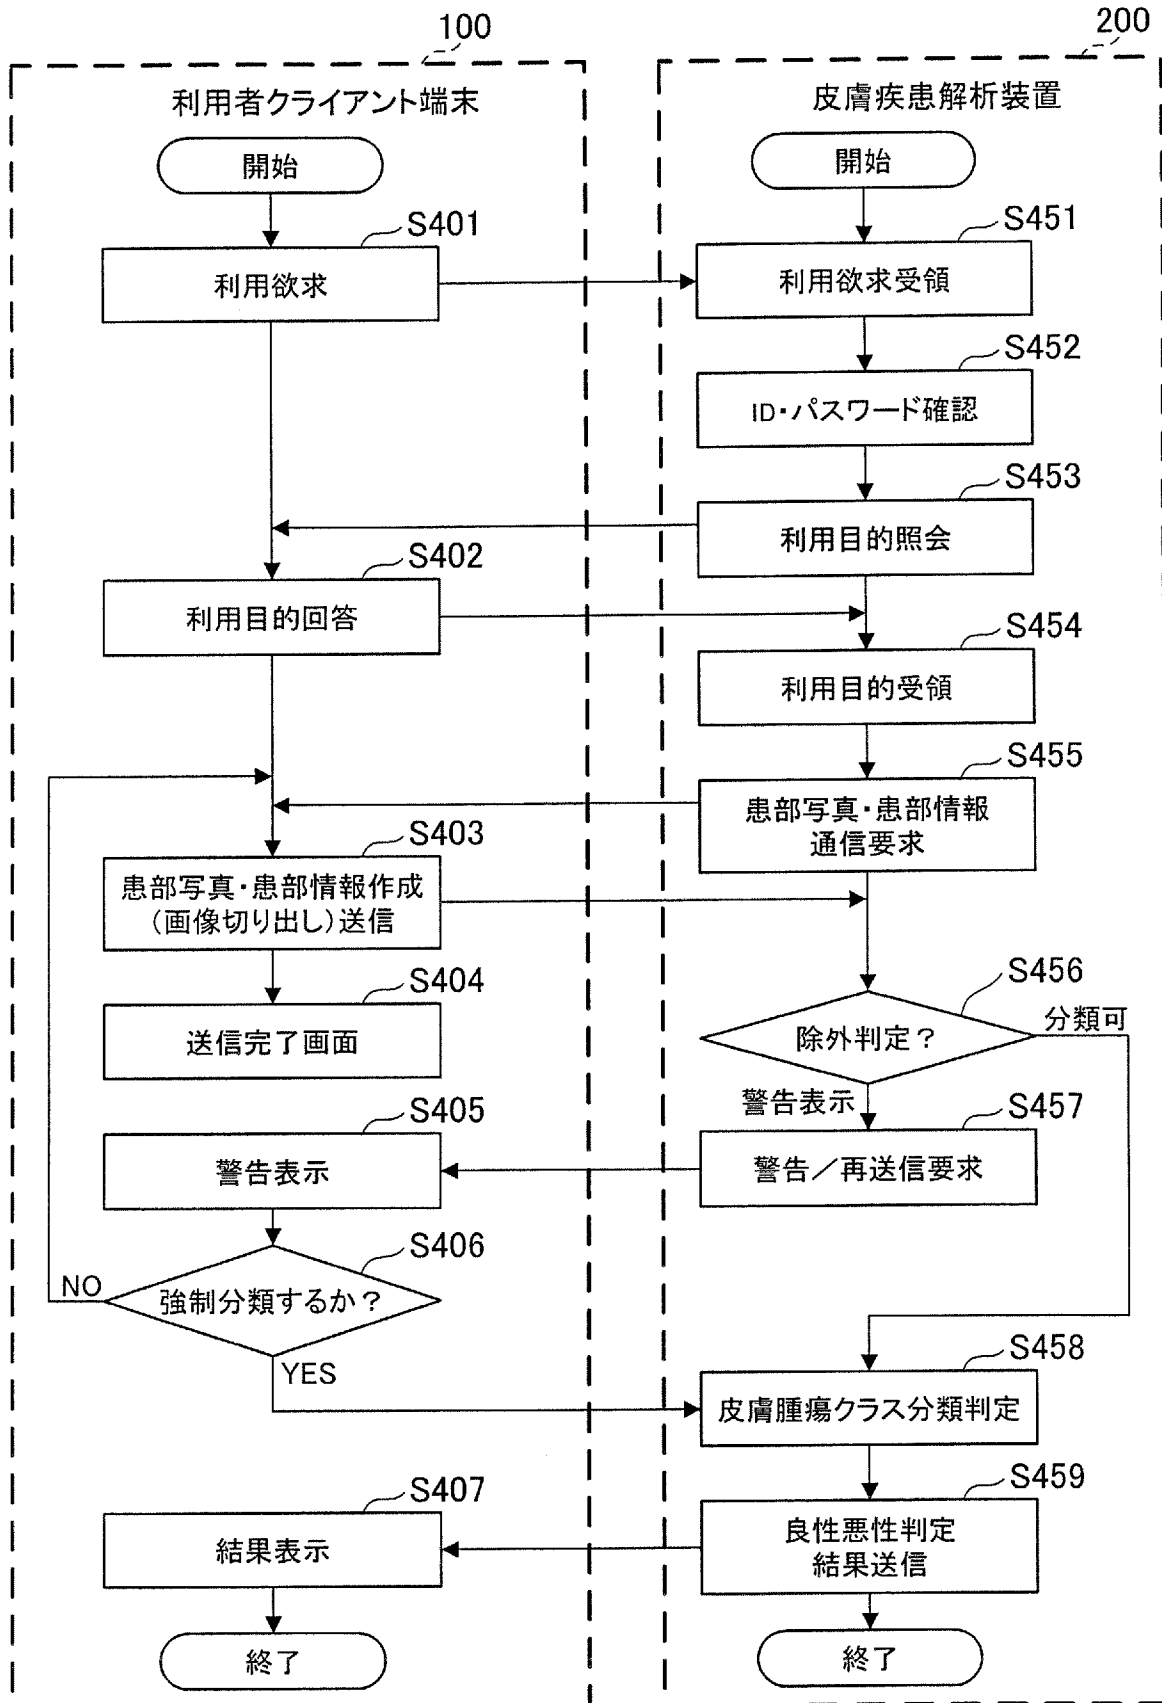
[図2]



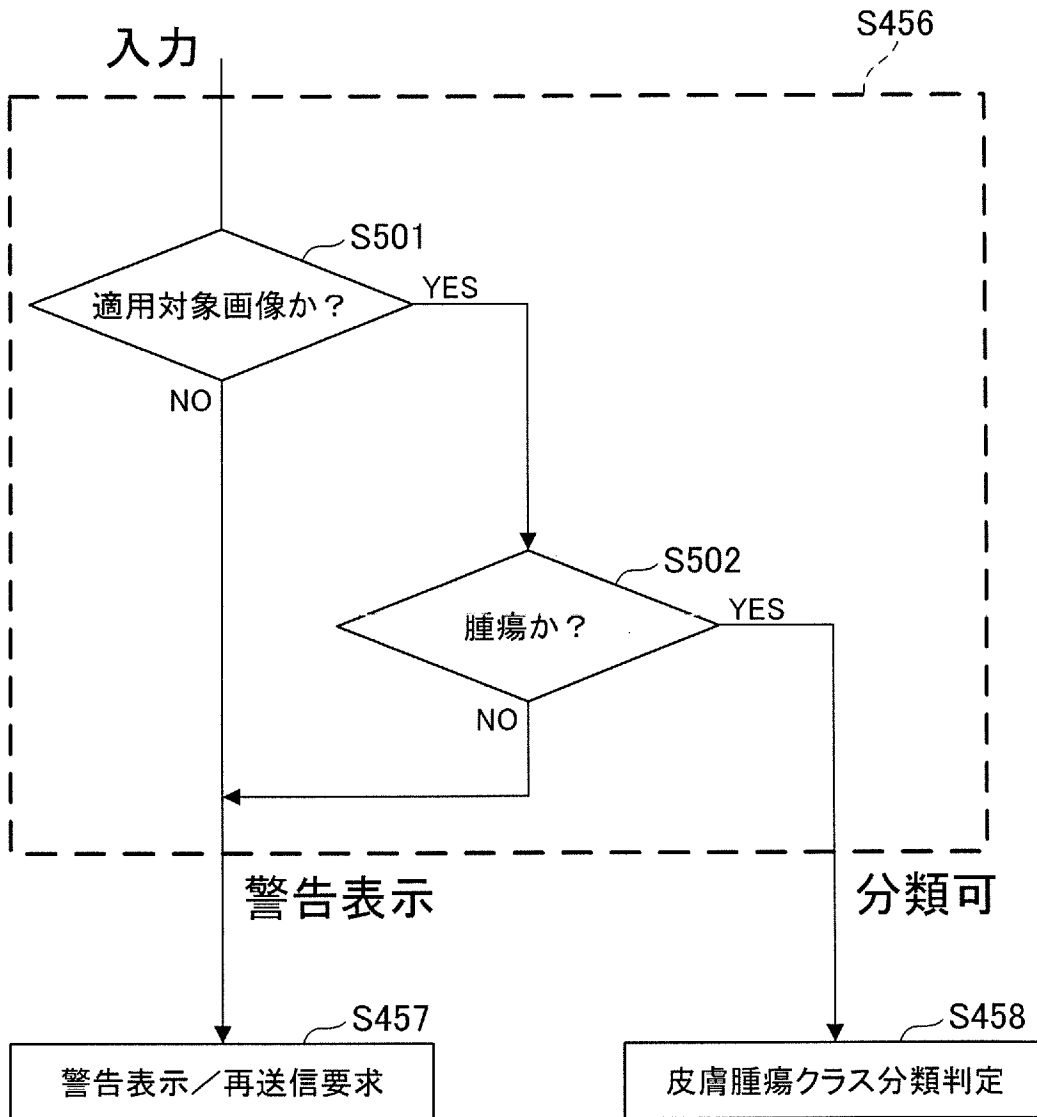
[図3]



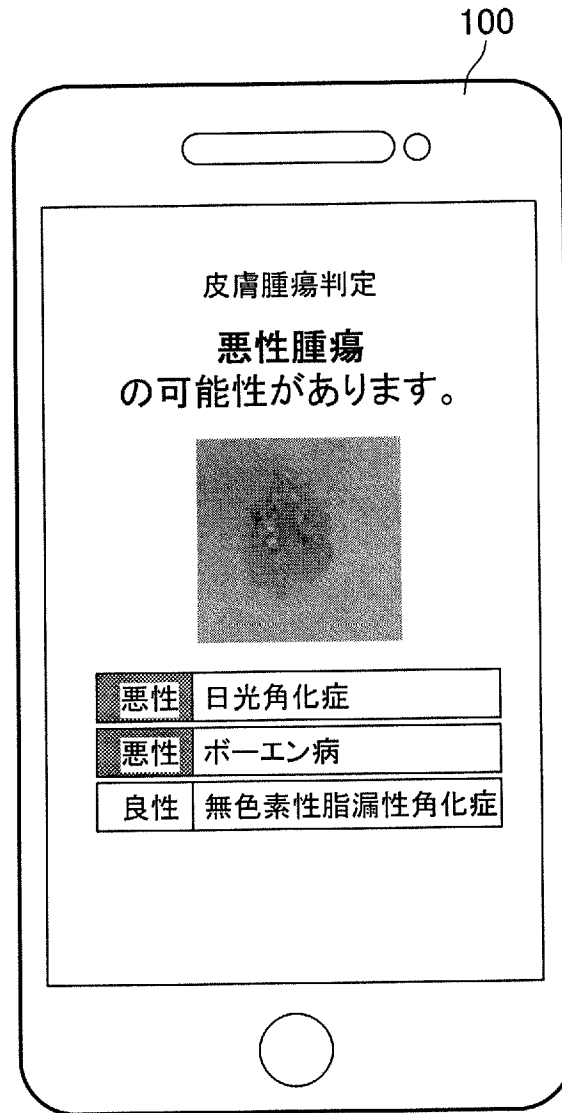
[図4]



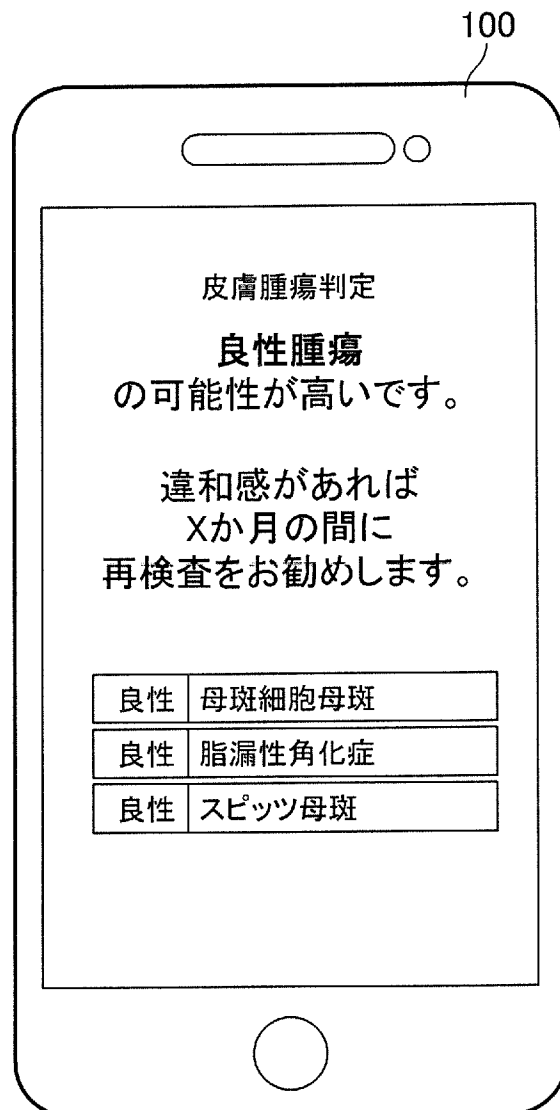
[図5]



[図6]



[図7]



[図8]

診断結果	悪性								良性													
	日光角化症	皮角日光角化症	ボーエン病	有棘細胞癌	基底細胞癌	無色素基底細胞癌	悪性メラノーマ	無色素悪性メラノーマ	汗孔腫	無色素汗孔腫	皮脂母斑	脂漏性角化症	無色素脂漏性角化症	青色母斑	メラニン細胞性母斑	母斑細胞母斑	無色素母斑細胞母斑	スピッツ母斑	無色素スピッツ母斑	黒子	扁平母斑	
本発明による出力																						
日光角化症	7			4												1						1
皮角日光角化症	2	6																				
ボーエン病	5		15	3		5									2							
有棘細胞癌	1	3	5	87	5	2	1	4		3						1						
基底細胞癌	2			1	72	5	2									1		1				
無色素基底細胞癌				5		9																
悪性メラノーマ				2			42	2		1								2				
無色素悪性メラノーマ								3														
汗孔腫				2					6													
無色素汗孔腫				1					1													
皮脂母斑										7												
脂漏性角化症		1	4	2	2		2		1	3					2							
無色素脂漏性角化症													1									
青色母斑													5									
メラニン細胞性母斑				2							1				15	5						
母斑細胞母斑	1		2		4		3			2				2	6	92		10				
無色素母斑細胞母斑						2										1	9					
スピッツ母斑									1							1		10				
無色素スピッツ母斑																	3		4			
黒子																2				2		17
扁平母斑	3		3				2									1						
総数	21	10	29	109	84	23	52	9	8	10	8	54	3	7	21	107	14	23	4	2	18	
感度 (%)	33.3	60	51.7	79.8	85.7	39.1	80.8	33.3	75	10	87.5	68.5	33.3	71.4	71.4	86	64.3	43.5	100	100	94.4	

[図9]

	診断結果																								
	悪性							良性																	
	日光角化症	皮膚日光角化症	ボウエン病	有棘細胞癌	基底細胞癌	無色素基底細胞癌	乳房外パジェット病	悪性メラノーマ	無色素悪性メラノーマ	血管肉腫	汗孔腫	無色素汗孔腫	皮脂母斑	脂漏性角化症	無色素脂漏性角化症	青色母斑	先天性色素性母斑	母斑細胞母斑	無色素母斑細胞母斑	スピッツ母斑	無色素スピッツ母斑	黒子	扁平母斑	化膿性肉芽腫	
AK	36		6	6	2	10		1		1	1			3											
AKhorn	2	10		1																					
Bowen	14		99	13	6	16		4	1		3		3	7				2		1					
SCC	14	18	18	293	17	19	2	2	8		10	8	4	4	2			4	2						3
BCC	4	1	4	9	257	1	14			2				13				23		2		2			
BCCamel	2		1	10	11	24				1								1							
EMPD	1				1		94			2															
MM		1		2	8			128	3	1				13		4	1	4		3					
MMamel				4				5	6		3														
AS	1									19		1		2	2										5
Poroma			1					1			9							2			2				
Poromamel				2	2			6	1		1	9													
SebaceousN								1					17												
SK	1		2	2	5			5				4		91	1			10		1					2
SKamel														1	7			1							1
BlueN					2			4								16		1							
CongenitalN		1						1		3				1				1							
NCN	1	2	1	1	21	4		27		1	5	4	1	27	3	6	5	283	2	25		4	4		
NCNamel				1	1						2							3	29						
Spitz					2			1			1									34					
Spitzamel				1														2							
Lentigo								1										5							
Spilus			1																						45
PG					2			1											1						24
疾患合計	76	33	133	344	337	74	96	202	19	30	34	30	21	164	15	27	57	345	39	66	7	11	53	34	2247
疾患の中	36	9	99	293	257	24	94	128	6	19	9	9	17	91	7	16	51	283	29	34	4	5	34	24	1578
悪性/良性的中	74	30	128	338	302	70	96	154	18	26	17	19	18	122	11	23	56	311	37	60	7	9	53	26	2005
recall(疾患)	0.47	0.27	0.74	0.85	0.76	0.32	0.98	0.63	0.32	0.63	0.26	0.30	0.81	0.55	0.47	0.59	0.89	0.82	0.74	0.52	0.57	0.45	0.64	0.71	0.70
recall(悪/良)	0.97	0.91	0.96	0.98	0.90	0.95	1.00	0.76	0.95	0.87	0.50	0.63	0.86	0.74	0.73	0.85	0.98	0.90	0.95	0.91	1.00	0.82	1.00	0.76	0.89

本発明による出力

[図10]

特定4クラス判定		医師による診断					
本発明による出力		BCC	MM	SK	NCN	計	予測率
	BCC	89	0	5	7	101	88%
	MM	3	43	4	3	53	81%
	SK	3	8	41	5	57	72%
	NCN	5	6	3	107	121	88%
計		100	57	53	122	332	
クラス正答率		89%	75%	77%	88%	84%	

[図11]

良性/悪性判定		医師による診断		計	的中率
		悪性	良性		
本発明による 出力	悪性	135	19	154	88%
	良性	22	156	178	98%
計		157	175	332	
		86%	89%	88%	
		感度	特異度	正診率	

[図12]

特定4クラス判定		診断結果					
本発明による出力		BCC	MM	SK	NCN	計	予測率
	BCC	100	3	6	11	120	83%
	MM	3	89	1	2	95	94%
	SK	2	1	44	5	52	85%
	NCN	5	5	4	111	121	92%
計		106	98	55	129	388	
クラス正答率		94%	91%	80%	86%	89%	

[図13]

良性/悪性判定		診断結果		計	的中率
		悪性	良性		
本発明による 出力	悪性	195	20	215	91%
	良性	9	164	173	95%
計		204	184	388	
		96%	89%	93%	
		感度	特異度	正診率	

[図14]

特定4クラス判定		診断結果				
本発明による出力		BCC	MM	SK	NCN	計
	BCC	57	1	4	8	70
	MM	2	50	0	1	53
	SK	2	0	30	1	34
	NCN	0	2	4	75	80
計		61	53	38	85	237
クラス正答率		93%	94%	79%	88%	89.4%

[図15]

良性/悪性判定		診断結果		計
		悪性	良性	
本発明による 出力	悪性	110	13	123
	良性	4	110	114
計		114	123	237
		96.5%	89.4%	92.8%
		感度	特異度	正診率

[図16]

特定4クラス判定		診断結果				
本発明による出力		BCC	MM	SK	NCN	計
	BCC	57	2	6	10	75
	MM	4	50	0	1	55
	SK	0	0	28	1	29
	NCN	0	1	4	73	78
計		61	53	38	85	237
クラス正答率		93%	94%	74%	86%	87.8%

[図17]

良性/悪性判定		診断結果		計
		悪性	良性	
本発明による 出力	悪性	113	17	130
	良性	1	106	107
計		114	123	237
		99.1%	86.1%	92.4%
		感度	特異度	正診率

[図18]

24クラス判定器のみ		診断結果		計
		悪性	良性	
本発明による 出力	悪性	151	65	215
	良性	46	162	207
計		196	226	422
		77%	71%	74%
		感度	特異度	正解率

[図19]

24クラス判定器→ BCC,MM,SK,NCN再判定		診断結果		計
		悪性	良性	
本発明による 出力	悪性	153	74	277
	良性	43	152	195
計		196	226	422
		78%	67%	72%
		感度	特異度	正解率

[図20]

24クラス判定器→ SK,NCN再判定		診断結果		計
		悪性	良性	
本発明による 出力	悪性	168	85	253
	良性	29	141	170
計		196	226	422
		85%	62%	73%
		感度	特異度	正解率

[図21]

	医師の診断	AI判定 第一候補	確信度1	AI判定 第二候補	確信度2
症例1					
画像1	MM	MM	0.68	SK	0.21
画像2	MM	SK	0.50	MM	0.48
画像3	MM	MM	0.99	Spitz	0.00
画像4	MM	MM	1.00	SK	0.00
画像5	MM	MM	0.57	CongenitalN	0.36
症例2					
画像1	MM	BlueN	0.48	MM	0.18
画像2	MM	BlueN	0.39	NCN	0.20
画像3	MM	MM	0.76	BlueN	0.09
画像4	MM	MM	0.66	NCN	0.16
画像5	MM	NCN	0.36	BlueN	0.31
症例3					
画像1	MM	BCC	0.57	MM	0.41
画像2	MM	BCC	0.53	MM	0.43
画像3	MM	MM	0.98	BCC	0.00

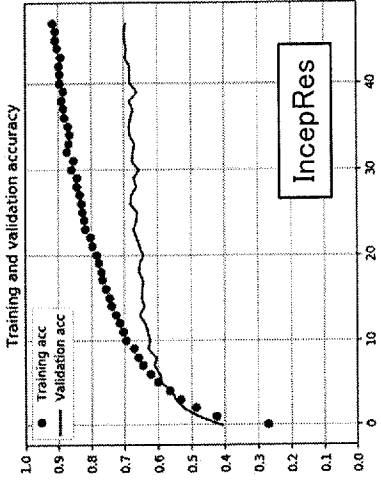
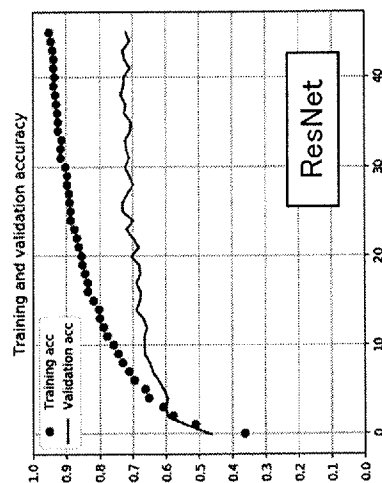
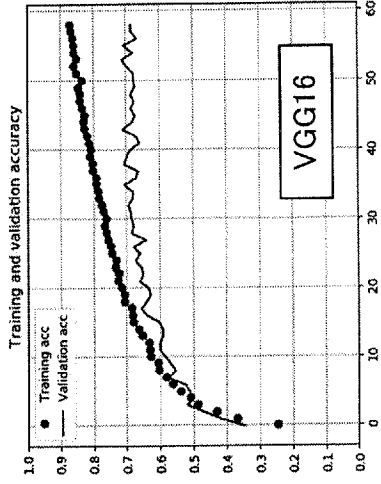
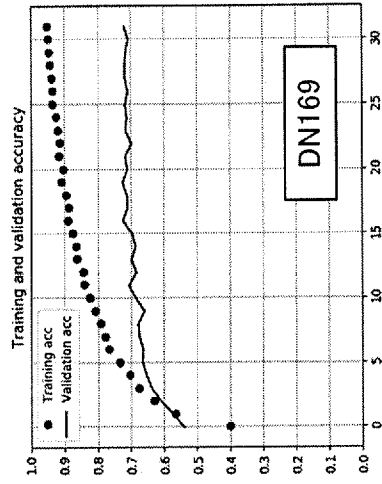
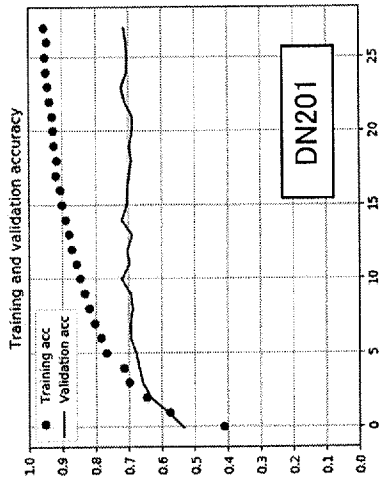
[図22]

確信度	母数	正解数	正解率
1	353	347	98.3%
0.99	185	177	95.7%
0.98	103	94	91.3%
0.90-0.97	324	260	80.2%
0.80-0.89	275	202	73.5%
0.70-0.79	219	144	65.8%
0.60-0.69	210	116	55.2%
0.40-0.59	403	202	50.1%
0-0.39	181	65	35.9%

[図23]

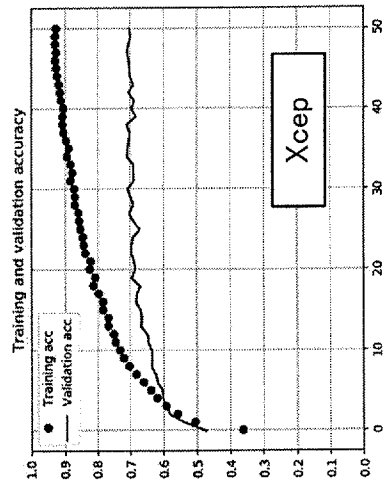
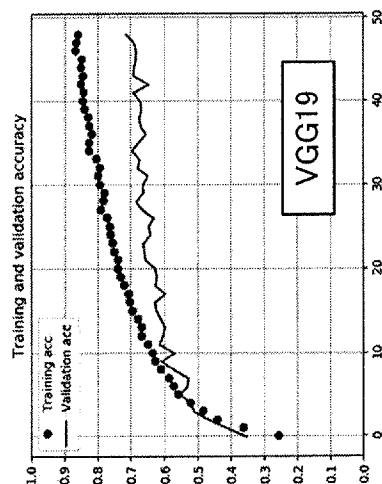
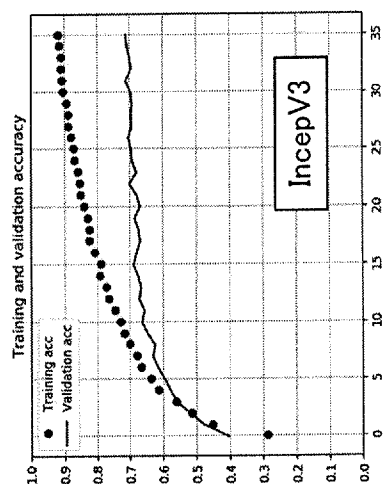
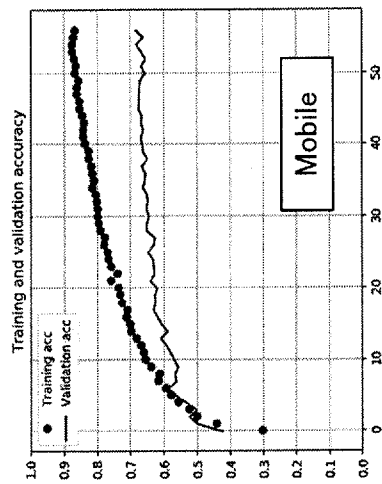
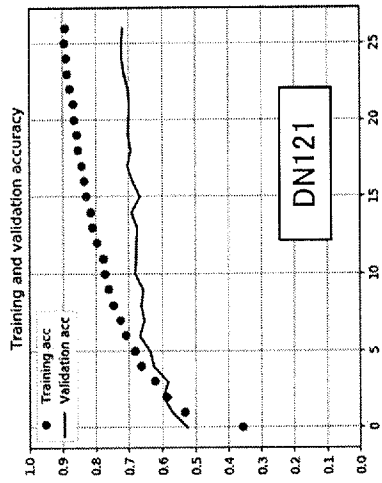
	MM	NCN
症例数(複数の画像を有する)	45	112
複数枚全正解	22	83
複数枚全不正解	10	8
確信度最大を選択すると正解	11	17
確信度最大を選択すると不正解	2	4
正解計	33	100

[図24]



実線:テストデータ  
点線:学習データ

[図25]



実線: テストデータ  
 点線: 学習データ

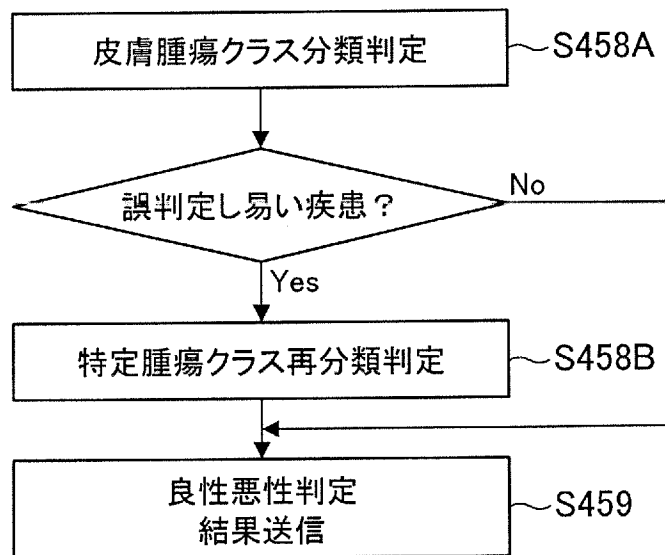
データ分割 3通り中、2番目

[図26]

モデルの種類	学習データにおける正解率と標準偏差				テストデータにおける正解率と標準偏差			
	24 classes		良性／悪性		24 classes		良性／悪性	
	mean	std	mean	std	mean	std	mean	std
DenseNet169	0.911	0.031	0.968	0.011	0.709	0.03	0.893	0.011
DenseNet201	0.899	0.012	0.966	0.005	0.708	0.033	0.886	0.016
Xception	0.894	0.051	0.962	0.02	0.706	0.039	0.891	0.017
MobileNet	0.884	0.024	0.956	0.008	0.694	0.021	0.883	0.016
InceptionV3	0.867	0.024	0.949	0.011	0.685	0.041	0.877	0.02
ResNet50	0.864	0.07	0.95	0.026	0.681	0.025	0.873	0.011
InceptionResNetV2	0.862	0.029	0.95	0.009	0.68	0.037	0.886	0.016
VGG19	0.859	0.024	0.953	0.01	0.675	0.039	0.885	0.015
DenseNet121	0.849	0.028	0.949	0.01	0.673	0.024	0.877	0.007
VGG16	0.848	0.028	0.947	0.011	0.666	0.025	0.874	0.012



[図28]



[表29]

	AK	Akhorn	Bowen	SCC	BCC	BCCamela	EMPD	MM	MMamela	AS	Poroma	Poromamela	SebacousN	SK	SKamela	Bluen	CongenitalN	NCN	NCNamela	Spitz	Spitzamela	Lentigo	Spilus	PG	総数	悪性又は良性	疾患	Precision(疾患)	Precision(良/悪)	
AK	136	10	9	22	17	19	2	4	0	1	0	0	3	5	6	0	0	1	0	0	0	0	3	0	238	220	136	0.57	0.92	
Akhorn	4	38	2	19	0	1	0	0	0	0	0	1	0	4	0	0	0	1	0	0	0	0	0	0	70	64	38	0.54	0.91	
Bowen	46	1	288	39	15	25	2	7	0	0	7	1	1	28	6	0	0	4	0	1	0	0	0	0	471	423	288	0.61	0.90	
SCC	26	47	40	922	51	47	6	6	19	6	30	15	0	25	2	2	1	3	1	0	1	0	0	9	1259	1170	922	0.73	0.93	
BCC	15	2	19	48	867	54	0	65	1	12	3	11	0	52	1	8	1	41	3	10	0	1	0	2	1216	1083	867	0.71	0.89	
BCCamela	14	0	11	36	14	79	0	0	0	2	1	0	1	1	3	0	0	0	7	0	0	0	0	3	172	156	79	0.46	0.91	
EMPD	6	0	6	12	3	1	330	0	0	9	0	2	2	0	0	0	0	0	0	0	0	0	0	0	371	367	330	0.89	0.99	
MM	1	3	7	21	30	2	0	463	15	3	4	6	0	26	0	2	21	29	0	5	0	4	1	4	647	545	463	0.72	0.84	
MMamela	0	0	0	9	0	0	0	6	16	0	8	5	0	0	0	0	0	0	0	0	0	0	0	0	44	31	16	0.36	0.70	
AS	0	0	6	0	2	0	3	0	0	48	0	0	0	1	0	0	0	0	0	0	0	0	0	0	60	59	48	0.80	0.98	
Poroma	0	0	4	2	0	1	0	0	1	0	28	6	1	0	3	0	0	1	3	0	0	0	0	0	3	61	53	28	0.46	0.87
Poromamela	0	0	0	4	6	0	1	6	0	0	2	18	0	6	0	0	0	2	0	1	0	0	0	2	48	31	18	0.38	0.65	
SebacousN	0	0	1	5	1	3	1	0	0	0	0	0	77	0	2	0	2	2	3	0	0	0	3	0	100	89	77	0.77	0.89	
SK	4	6	14	12	37	0	0	32	0	1	1	11	0	302	3	2	1	23	0	6	0	1	1	2	459	353	302	0.66	0.77	
SKamela	0	0	2	2	0	5	0	0	0	0	1	0	0	1	26	0	0	2	4	0	0	0	2	0	45	36	26	0.58	0.80	
Bluen	0	0	0	0	9	0	0	3	0	0	0	1	0	2	0	79	0	8	0	4	0	0	0	0	106	94	79	0.75	0.89	
CongenitalN	0	0	0	0	0	0	0	7	0	2	0	0	0	0	0	0	149	18	0	1	0	0	16	0	193	184	149	0.77	0.95	
NCN	7	0	7	0	44	13	0	43	1	0	9	14	0	56	0	21	53	947	22	42	0	19	7	0	1305	1190	947	0.73	0.91	
NCNamela	0	0	2	4	0	10	0	0	0	0	1	2	9	0	10	0	0	9	86	0	2	0	0	0	135	119	86	0.64	0.88	
Spitz	0	0	1	0	6	0	0	3	0	0	1	3	0	3	0	7	2	28	0	122	1	1	0	0	178	168	122	0.69	0.94	
Spitzamela	0	0	0	1	0	0	0	0	0	0	8	0	0	0	1	0	0	1	0	0	0	14	0	1	26	25	14	0.54	0.96	
Lentigo	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8	0	0	0	19	0	0	27	27	19	0.70	1.00	
Spilus	1	1	2	0	0	0	0	1	0	0	0	0	0	0	0	0	2	2	0	0	0	1	143	0	153	148	143	0.93	0.97	
PG	0	0	0	1	0	0	0	0	5	0	0	2	0	0	0	0	0	0	1	0	3	0	0	76	88	76	0.86	0.93		
総数	260	108	421	1159	1102	260	345	646	58	84	104	98	94	512	63	121	232	1130	130	192	29	46	176	102	7472	6717	5273	0.71	0.90	
正解:悪性/良性	248	101	388	1128	999	228	343	551	51	81	51	57	87	370	45	109	209	1051	119	176	28	41	172	84	6717	84	6717			
正解:疾患	136	38	288	922	867	79	330	463	16	48	28	18	77	302	26	79	149	947	86	122	14	19	143	76	5273	76	5273			
recall(疾患)	0.52	0.35	0.68	0.8	0.79	0.3	0.96	0.72	0.28	0.57	0.27	0.18	0.82	0.59	0.41	0.65	0.64	0.84	0.66	0.64	0.48	0.41	0.81	0.75	0.71	0.71	0.71			
recall(良/悪)	0.95	0.94	0.92	0.97	0.91	0.88	0.99	0.85	0.88	0.96	0.49	0.58	0.93	0.72	0.71	0.9	0.9	0.93	0.92	0.92	0.97	0.89	0.98	0.82	0.9	0.82	0.9			

[図30]

実施例13においてAI判定がPoromamelaであったもの  
診断結果 4クラス再判定結果

BCC	6	悪性	BCC	6	悪性
EMPD	1		MM	1	悪性
MM	6		BCC	1	悪性
SCC	4		MM	5	悪性
			BCC	2	悪性
		NCN	1	良性	
		SK	1	良性	
NCN	2	良性	NCN	2	良性
PG	2		NCN	2	良性
Poroma	2		BCC	1	悪性
			NCN	1	良性
SK	6		SK	6	良性
Spitz	1		NCN	1	良性
Poromamela	18		BCC	2	悪性
			MM	11	悪性
		NCN	3	良性	
		SK	2	良性	

[図31]

症例番号	診断	写真 番号	除外判定		24クラス判定1位		24クラス判定2位		24クラス判定3位		4クラス判定1位		悪性/良性AI判定	
			判定	確信度	判定	確信度	判定	確信度	判定	確信度	判定	確信度	判定	確信度
1	BCC	1	N	0.9879	BCC	0.9989	BlueN	0.0024	SCC	0.0003	—	—	BCC	○
		2	N	0.9578	BCC	0.9881	BlueN	0.0112	MM	0.0003	—	—	—	
		3	N	0.9815	BCC	0.9967	BlueN	0.0027	SCC	0.0002	—	—	—	
		4	N	0.9908	BCC	0.9874	BlueN	0.0072	MM	0.0025	—	—	—	
2	BCC	1	N	0.7057	BCC	0.9988	NCN	0.0003	SK	0.0003	—	—	—	
		2	N	0.9887	BCC	0.9993	NCN	0.0003	Bowen	0.0001	—	—	—	
		3	N	0.9573	BCC	0.9990	Bowen	0.0004	NCN	0.0002	—	—	—	
		4	N	0.9620	BCC	0.9994	SK	0.0002	Bowen	0.0002	—	—	BCC	○
3	BCC	1	N	1.0000	MM	0.5120	SCC	0.3118	Poromamela	0.1126	—	—	MM	○
		2	N	1.0000	MM	0.5032	SCC	0.3847	BCC	0.0604	—	—	—	
		3	N	0.9997	MM	0.4876	SCC	0.4231	Poromamela	0.0247	—	—	—	
		4	N	1.0000	SCC	0.4571	MM	0.4123	Poromamela	0.0780	—	—	—	
4	BCC	1	N	0.9999	BCC	0.7614	MM	0.1166	SCC	0.0755	—	—	—	
		2	N	1.0000	BCC	0.9486	MM	0.0204	SCC	0.0184	—	—	BCC	○
		3	N	0.9999	MM	0.5477	BCC	0.2844	SCC	0.0920	—	—	—	
		4	N	0.9999	MM	0.4530	BCC	0.4296	SCC	0.0749	—	—	—	
5	BCC	1	N	0.9998	BCC	0.9946	MM	0.0034	AS	0.0018	—	—	—	
		2	N	0.9955	BCC	0.9488	MM	0.0420	AS	0.0081	—	—	—	
		3	N	0.9998	BCC	0.9986	MM	0.0012	AS	0.0001	—	—	BCC	○
		4	N	0.9981	BCC	0.9837	MM	0.0157	AS	0.0003	—	—	—	
6	BCC	1	A	0.6533	—	—	—	—	—	—	—	—	—	
		2	N	0.5112	BCC	0.7730	NCN	0.1163	NCNamela	0.0356	—	—	BCC	○
		3	N	0.9242	NCN	0.5467	NCNamela	0.1293	Spilus	0.0789	MM	0.6847	—	
		欠	—	—	—	—	—	—	—	—	—	—	—	

除外判定の欄において、「N」は皮膚腫瘍と判定されたこと、「A」は皮膚腫瘍ではないと判定されたことを示す

**INTERNATIONAL SEARCH REPORT**

International application No. PCT/JP2020/013684
--

**A. CLASSIFICATION OF SUBJECT MATTER**  
 G16H 50/20 (2018.01) i; A61B 5/00 (2006.01) i; A61B 10/00 (2006.01) i  
 FI: G16H50/20; A61B10/00 Q; A61B5/00 M

According to International Patent Classification (IPC) or to both national classification and IPC

**B. FIELDS SEARCHED**

Minimum documentation searched (classification system followed by classification symbols)  
 G16H10/00-80/00; A61B5/00; A61B10/00

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Published examined utility model applications of Japan	1922-1996
Published unexamined utility model applications of Japan	1971-2020
Registered utility model specifications of Japan	1996-2020
Published registered utility model applications of Japan	1994-2020

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

**C. DOCUMENTS CONSIDERED TO BE RELEVANT**

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
X	JP 2005-192944 A (KEIO GIJUKU) 21.07.2005 (2005-07-21) paragraphs [0004]-[0116]	1-12, 15-18, 20-25
Y	paragraphs [0004]-[0116]	13-14, 19
Y	JP 2015-158738 A (TOSHIBA CORP.) 03.09.2015 (2015-09-03) paragraphs [0007], [0119]-[0120]	13
Y	JP 2004-5262 A (ALLIANCE GROUP INC.) 08.01.2004 (2004-01-08) paragraph [0013]	14
Y	JP 2018-147405 A (CASIO COMPUTER CO., LTD.) 20.09.2018 (2018-09-20) paragraph [0023]	19
A	JP 2005-58398 A (NEC FIELDING, LTD.) 10.03.2005 (2005-03-10) entire text, all drawings	1-25
A	JP 2008-234627 A (SEIKO EPSON CORP.) 02.10.2008 (2008-10-02) entire text, all drawings	1-25

<input checked="" type="checkbox"/> Further documents are listed in the continuation of Box C.	<input checked="" type="checkbox"/> See patent family annex.
--	--

* Special categories of cited documents:	“T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention
“A” document defining the general state of the art which is not considered to be of particular relevance	“X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone
“E” earlier application or patent but published on or after the international filing date	“Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art
“L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)	“&” document member of the same patent family
“O” document referring to an oral disclosure, use, exhibition or other means	
“P” document published prior to the international filing date but later than the priority date claimed	

Date of the actual completion of the international search 10 June 2020 (10.06.2020)	Date of mailing of the international search report 23 June 2020 (23.06.2020)
--	---

Name and mailing address of the ISA/ Japan Patent Office 3-4-3, Kasumigaseki, Chiyoda-ku, Tokyo 100-8915, Japan	Authorized officer  Telephone No.
--	---

**INTERNATIONAL SEARCH REPORT**

International application No.

PCT/JP2020/013684

C (Continuation). DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	JP 2017-510792 A (VENTANA MEDICAL SYSTEMS, INC.) 13.04.2017 (2017-04-13) entire text, all drawings	1-25

**INTERNATIONAL SEARCH REPORT**  
Information on patent family members

International application No.  
PCT/JP2020/013684

Patent Documents referred in the Report	Publication Date	Patent Family	Publication Date
JP 2005-192944 A	21 Jul. 2005	US 2008/0275315 A1 paragraphs [0003]- [0059], [0071]-[0141] WO 2005/065534 A1 (Family: none)	
JP 2015-158738 A	03 Sep. 2015	(Family: none)	
JP 2004-5262 A	08 Jan. 2004	(Family: none)	
JP 2018-147405 A	20 Sep. 2018	US 2018/0260970 A1 paragraph [0029] EP 3373204 A CN 1085 73485 A CA 2994129 A1 (Family: none)	
JP 2005-58398 A	10 Mar. 2005	(Family: none)	
JP 2008-234627 A	02 Oct. 2008	US 2008/0199084 A1 entire text, all drawings	
JP 2017-510792 A	13 Apr. 2017	US 2016/0335478 A1 entire text, all drawings US 2019/0038310 A1 WO 2015/113895 A1	

A. 発明の属する分野の分類（国際特許分類（IPC）） G16H 50/20(2018.01)i; A61B 5/00(2006.01)i; A61B 10/00(2006.01)i FI: G16H50/20; A61B10/00 Q; A61B5/00 M		
B. 調査を行った分野 調査を行った最小限資料（国際特許分類（IPC）） G16H10/00-80/00; A61B5/00; A61B10/00 最小限資料以外の資料で調査を行った分野に含まれるもの 日本国実用新案公報 1922-1996年 日本国公開実用新案公報 1971-2020年 日本国実用新案登録公報 1996-2020年 日本国登録実用新案公報 1994-2020年		
国際調査で使用した電子データベース（データベースの名称、調査に使用した用語）		
C. 関連すると認められる文献		
引用文献の カテゴリー*	引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示	関連する 請求項の番号
X	JP 2005-192944 A (学校法人慶應義塾) 21.07.2005 (2005-07-21) 段落[0004]-[0116]	1-12, 15-18, 20-25
Y	段落[0004]-[0116]	13-14, 19
Y	JP 2015-158738 A (株式会社東芝) 03.09.2015 (2015-09-03) 段落[0007], [0119]-[0120]	13
Y	JP 2004-5262 A (株式会社アライアンスグループ) 08.01.2004 (2004-01-08) 段落[0013]	14
Y	JP 2018-147405 A (カシオ計算機株式会社) 20.09.2018 (2018-09-20) 段落[0023]	19
A	JP 2005-58398 A (NECフィールディング株式会社) 10.03.2005 (2005-03-10) 全文, 全図	1-25
A	JP 2008-234627 A (セイコーエプソン株式会社) 02.10.2008 (2008-10-02) 全文, 全図	1-25
<input checked="" type="checkbox"/> C欄の続きにも文献が列挙されている。 <input checked="" type="checkbox"/> パテントファミリーに関する別紙を参照。		
* 引用文献のカテゴリー “A” 特に関連のある文献ではなく、一般的な技術水準を示すもの “E” 国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの “L” 優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献（理由を付す） “O” 口頭による開示、使用、展示等に言及する文献 “P” 国際出願日前で、かつ優先権の主張の基礎となる出願の日の後に公表された文献 “T” 国際出願日又は優先日後に公表された文献であって出願と抵触するものではなく、発明の原理又は理論の理解のために引用するもの “X” 特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの “Y” 特に関連のある文献であって、当該文献と他の1以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの “&” 同一パテントファミリー文献		
国際調査を完了した日	国際調査報告の発送日	
10.06.2020	23.06.2020	
名称及びあて先 日本国特許庁 (ISA/JP) 〒100-8915 日本国 東京都千代田区霞が関三丁目4番3号	権限のある職員（特許庁審査官）  岸 健司 5R 6300  電話番号 03-3581-1101 内線 3502	

C. 関連すると認められる文献		
引用文献の カテゴリー*	引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示	関連する 請求項の番号
A	JP 2017-510792 A (ペンタナ メディカル システムズ, インコーポレイテッド) 13.04.2017 (2017 - 04 - 13) 全文, 全図	1-25

国際調査報告  
 パテントファミリーに関する情報

国際出願番号

PCT/JP2020/013684

引用文献	公表日	パテントファミリー文献	公表日
JP 2005-192944 A	21.07.2005	US 2008/0275315 A1 段落[0003]-[0059], [0071]-[0141] WO 2005/065534 A1	
JP 2015-158738 A	03.09.2015	(ファミリーなし)	
JP 2004-5262 A	08.01.2004	(ファミリーなし)	
JP 2018-147405 A	20.09.2018	US 2018/0260970 A1 段落[0029] EP 3373204 A CN 108573485 A CA 2994129 A1	
JP 2005-58398 A	10.03.2005	(ファミリーなし)	
JP 2008-234627 A	02.10.2008	US 2008/0199084 A1 全文, 全図	
JP 2017-510792 A	13.04.2017	US 2016/0335478 A1 全文, 全図 US 2019/0038310 A1 WO 2015/113895 A1	