

(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2012-181704

(P2012-181704A)

(43) 公開日 平成24年9月20日 (2012.9.20)

(51) Int.Cl.			F I			テーマコード (参考)	
G06T	13/00	(2011.01)	G06T	13/00	A	2C001	
G06T	13/80	(2011.01)	G06F	3/048	651A	5B050	
G06F	3/048	(2006.01)	A63F	13/00	C	5E501	
A63F	13/00	(2006.01)	A63F	13/00	E		
A63F	13/02	(2006.01)	A63F	13/02			

審査請求 未請求 請求項の数 9 O L (全 21 頁)

(21) 出願番号 特願2011-44488 (P2011-44488)
 (22) 出願日 平成23年3月1日 (2011.3.1)

(71) 出願人 310021766
 株式会社ソニー・コンピュータエンタテインメント
 東京都港区港南1丁目7番1号
 (74) 代理人 100105924
 弁理士 森下 賢樹
 (74) 代理人 100109047
 弁理士 村田 雄祐
 (74) 代理人 100109081
 弁理士 三木 友由
 (74) 代理人 100134256
 弁理士 青木 武司

最終頁に続く


(54) 【発明の名称】 情報処理装置および情報処理方法

(57) 【要約】

【課題】 ネットワークを介したリアルタイムな会話システムを容易な計算で実現する。

【解決手段】 情報処理装置 10 a の送信データ作成部 60 において、基本画像特定部 62 は自ユーザを表すキャラクタの基本的な画像を特定する。顔認識部 64 は自ユーザの顔認識を行う。表情パラメータ生成部 66 は自ユーザの表情を数値化する。モデル制御部 68 は、各時刻に対しキャラクタの出力モデルを決定する。動画パラメータ生成部 70 は、キャラクタのアニメーション動画のフレームを各時刻において生成するための動画パラメータを生成する。コマンド特定部 72 は、自ユーザの表情のパターンに対応するコマンドを特定する。受信データ処理部 80 において、再生部 82 は相手の情報処理装置から受信した動画パラメータおよび音声データに基づき音声および画像を出力する。コマンド実行部 84 はコマンドの識別情報に基づきコマンドを実行する。

【選択図】 図 3



【特許請求の範囲】**【請求項 1】**

ユーザを表すキャラクタのモデルであり、異なる表情を有する複数の表情モデルのデータを格納した画像データ格納部と、

ユーザを撮影して得られる入力動画像データを逐次解析し、入力画像フレームごとに顔の部位の形状を表す数値を導出し、あらかじめ設定した基準値と比較することにより、表情の種類ごとに、表情がなされている度合いを表情パラメータとして算出する表情パラメータ生成部と、

前記表情パラメータ生成部が算出した表情パラメータ、および、撮影と同時に取得した当該ユーザの音声データから得られる声量を用いて、前記画像データ格納部に格納された複数の表情モデルに対する重みを決定したうえで、当該複数の表情モデルを合成し、前記入力画像フレームに対応する各時刻におけるキャラクタの出力モデルを決定するモデル制御部と、

前記モデル制御部が決定した出力モデルを含むキャラクタのアニメーション動画のフレームを各時刻において生成するための動画パラメータを生成する動画パラメータ生成部と、

前記動画パラメータ生成部が生成した動画パラメータと前記音声データとを同期させて逐次出力する出力部と、

を備えたことを特徴とする情報処理装置。

【請求項 2】

前記画像データ格納部が格納する複数の表情モデルは、異なる音を発声したときの顔の状態を表す複数の発声モデルを含み、

前記モデル制御部は、前記複数の発声モデルに対する重みを異なる波形で時間変化させて合成することを特徴とする請求項 1 に記載の情報処理装置。

【請求項 3】

前記異なる波形は、前記声量に比例した振幅を有し、周期の異なる正弦波の絶対値であることを特徴とする請求項 2 に記載の情報処理装置。

【請求項 4】

前記発声モデルは、「あ」を発声したときの顔の状態を表す発声モデルと、「い」を発声したときの顔の状態を表す発声モデルと、「う」を発声したときの顔の状態を表す発声モデルであることを特徴とする請求項 2 または 3 に記載の情報処理装置。

【請求項 5】

前記表情パラメータ生成部が生成する表情パラメータは口を開けている度合いを含み、前記モデル制御部は、前記発声モデルに対する重みの少なくともいずれかに、前記口を開けている度合いを加算することを特徴とする請求項 2 から 4 のいずれかに記載の情報処理装置。

【請求項 6】

前記出力部は、ネットワークを介して他の情報処理装置へ、前記動画パラメータを逐次送信することを特徴とする請求項 1 から 5 のいずれかに記載の情報処理装置。

【請求項 7】

ユーザを撮影して得られる入力動画像データを逐次解析し、入力画像フレームごとに顔の部位の形状を表す数値を導出し、あらかじめ設定した基準値と比較することにより、表情の種類ごとに、当該表情がなされている度合いを表情パラメータとして算出するステップと、

算出した表情パラメータ、および、撮影と同時に取得した当該ユーザの音声データから得られる声量を用いて、メモリに記憶された、ユーザを表すキャラクタのモデルであり、異なる表情を有する複数の表情モデルに対する重みを決定するステップと、

メモリから前記複数の表情モデルのデータを読み出すステップと、

当該複数の表情モデルを前記重みによって重みづけして合成し、前記入力画像フレームに対応する各時刻におけるキャラクタの出力モデルを決定するステップと、

10

20

30

40

50

前記出力モデルを含むキャラクタのアニメーション動画のフレームを各時刻において生成するための動画パラメータを生成するステップと、

前記動画パラメータと前記音声データとを同期させて逐次出力するステップと、
を含むことを特徴とする情報処理方法。

【請求項 8】

ユーザを撮影して得られる入力動画像データを逐次解析し、入力画像フレームごとに顔の部位の形状を表す数値を導出し、あらかじめ設定した基準値と比較することにより、表情の種類ごとに、当該表情がなされている度合いを表情パラメータとして算出する機能と、

算出した表情パラメータ、および、撮影と同時に取得した当該ユーザの音声データから得られる声量を用いて、メモリに記憶された、ユーザを表すキャラクタのモデルであり、異なる表情を有する複数の表情モデルに対する重みを決定する機能と、

メモリから前記複数の表情モデルのデータを読み出す機能と、

当該複数の表情モデルを前記重みによって重みづけして合成し、前記入力画像フレームに対応する各時刻におけるキャラクタの出力モデルを決定する機能と、

前記出力モデルを含むキャラクタのアニメーション動画のフレームを各時刻において生成するための動画パラメータを生成する機能と、

前記動画パラメータと前記音声データとを同期させて逐次出力する機能と、

をコンピュータに実現させることを特徴とするコンピュータプログラム。

【請求項 9】

ユーザを撮影して得られる入力動画像データを逐次解析し、入力画像フレームごとに顔の部位の形状を表す数値を導出し、あらかじめ設定した基準値と比較することにより、表情の種類ごとに、当該表情がなされている度合いを表情パラメータとして算出する機能と、

算出した表情パラメータ、および、撮影と同時に取得した当該ユーザの音声データから得られる声量を用いて、メモリに記憶された、ユーザを表すキャラクタのモデルであり、異なる表情を有する複数の表情モデルに対する重みを決定する機能と、

メモリから前記複数の表情モデルのデータを読み出す機能と、

当該複数の表情モデルを前記重みによって重みづけして合成し、前記入力画像フレームに対応する各時刻におけるキャラクタの出力モデルを決定する機能と、

前記出力モデルを含むキャラクタのアニメーション動画のフレームを各時刻において生成するための動画パラメータを生成する機能と、

前記動画パラメータと前記音声データとを同期させて逐次出力する機能と、

をコンピュータに実現させることを特徴とするコンピュータプログラムを記録した記録媒体。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、ユーザがネットワークを介して会話するための会話システムに用いる情報処理装置および情報処理方法に関する。

【背景技術】

【0002】

遠隔地にいるユーザの画像および音声のデータをネットワークを介して相互に受信し、表示画像および音響として出力することにより、距離を感じずに会話することのできるテレビ会議システムが実用化されている。現在では、ウェブカメラを搭載したパーソナルコンピュータ、携帯端末、ゲーム機器の普及、ネットワークの拡充などの要因により、会議など特定の場面に限らず、より個人的に、時間、場所を問わず気軽に楽しめるビデオチャットやテレビ電話などの技術も一般的になってきた（例えば特許文献 1 参照）。

【先行技術文献】

【特許文献】

10

20

30

40

50

【 0 0 0 3 】

【特許文献 1】米国公開 2 0 0 9 / 2 2 2 5 7 2 号公報

【発明の概要】

【発明が解決しようとする課題】

【 0 0 0 4 】

上記技術を利用してより自然な会話を楽しむには、リアルタイム性を維持することが重要である。しかしながら質の高い画像および音声のデータをレイテンシなく伝送して出力するためには、相応のデータ処理能力、通信帯域が必要となる。そのため通信帯域に制約があったり、一つの情報処理装置で並行して何らかの処理を行っていたりするような環境においても、気軽に、かつ自然な会話を楽しむことのできる技術が望まれている。

10

【 0 0 0 5 】

本発明はこのような課題に鑑みてなされたものであり、その目的は、処理のためのリソースや通信帯域を圧迫することなく、相手ユーザとのリアルタイムな会話を楽しむことができる技術を提供することにある。本発明の別の目的は、そのような会話において娯楽性を高めることのできる技術を提供することにある。

【課題を解決するための手段】

【 0 0 0 6 】

本発明のある態様は情報処理装置に関する。この情報処理装置は、ユーザを表すキャラクタのモデルであり、異なる表情を有する複数の表情モデルのデータを格納した画像データ格納部と、ユーザを撮影して得られる入力動画像データを逐次解析し、入力画像フレームごとに顔の部位の形状を表す数値を導出し、あらかじめ設定した基準値と比較することにより、表情の種類ごとに、表情がなされている度合いを表情パラメータとして算出する表情パラメータ生成部と、表情パラメータ生成部が算出した表情パラメータ、および、撮影と同時に取得した当該ユーザの音声データから得られる音量を用いて、画像データ格納部に格納された複数の表情モデルに対する重みを決定したうえで、当該複数の表情モデルを合成し、入力画像フレームに対応する各時刻におけるキャラクタの出力モデルを決定するモデル制御部と、モデル制御部が決定した出力モデルを含むキャラクタのアニメーション動画のフレームを各時刻において生成するための動画パラメータを生成する動画パラメータ生成部と、動画パラメータ生成部が生成した動画パラメータと前記音声データとを同期させて逐次出力する出力部と、を備えたことを特徴とする。

20

30

【 0 0 0 7 】

本発明のさらに別の態様は情報処理方法に関する。この情報処理方法は、ユーザを撮影して得られる入力動画像データを逐次解析し、入力画像フレームごとに顔の部位の形状を表す数値を導出し、あらかじめ設定した基準値と比較することにより、表情の種類ごとに、当該表情がなされている度合いを表情パラメータとして算出するステップと、算出した表情パラメータ、および、撮影と同時に取得した当該ユーザの音声データから得られる音量を用いて、メモリに記憶された、ユーザを表すキャラクタのモデルであり、異なる表情を有する複数の表情モデルに対する重みを決定するステップと、メモリから前記複数の表情モデルのデータを読み出すステップと、当該複数の表情モデルを重みによって重みづけして合成し、入力画像フレームに対応する各時刻におけるキャラクタの出力モデルを決定するステップと、出力モデルを含むキャラクタのアニメーション動画のフレームを各時刻において生成するための動画パラメータを生成するステップと、動画パラメータと音声データとを同期させて逐次出力するステップと、を含むことを特徴とする。

40

【 0 0 0 8 】

なお、以上の構成要素の任意の組合せ、本発明の表現を方法、装置、システム、コンピュータプログラム、コンピュータプログラムを記録した記録媒体などの間で変換したものもまた、本発明の態様として有効である。

【発明の効果】

【 0 0 0 9 】

本発明によると、処理のためのリソースや通信帯域を圧迫することなく、相手ユーザと

50

のネットワークを介した自然な会話を楽しむことが可能となる。また、会話に娯楽性を含めることができる。

【図面の簡単な説明】

【0010】

【図1】本実施の形態に適用できる会話システムの使用環境を示す図である。

【図2】本実施の形態における情報処理装置の内部回路構成を示す図である。

【図3】本実施の形態における情報処理装置の構成を詳細に示す図である。

【図4】本実施の形態において表示される画像の例を示す図である。

【図5】本実施の形態における基本画像IDテーブルのデータ構造例を示す図である。

【図6】本実施の形態における基本画像IDテーブルのデータ構造の別の例を示す図である。

10

【図7】本実施の形態における表情判定基準のデータ構造例を示す図である。

【図8】本実施の形態においてモデル制御部がキャラクタの顔を合成する様子を模式的に示す図である。

【図9】本実施の形態におけるコマンドIDテーブルのデータ構造例を示す図である。

【発明を実施するための形態】

【0011】

図1は本実施の形態を適用できる会話システムの使用環境を示す。会話システム1は、ユーザ12aが操作する情報処理装置10a、ユーザ12bが操作する情報処理装置10bなど複数の情報処理装置を含む。情報処理装置10a、10bがそれぞれ、インターネットやLAN(Local Area Network)などのネットワーク8に接続し、画像および音声のデータを相手の装置に送ることにより、ユーザ同士の会話を実現する。なお情報処理装置10とネットワーク8との接続は同図のとおり無線通信であってもよいし、有線ケーブルを介していてもよい。

20

【0012】

本実施の形態では、ネットワーク8を介して通信を確立した情報処理装置10a、10bをそれぞれ操作するユーザ12a、12bの実物の映像に代わり、それぞれのユーザを表す仮想のキャラクタをコンピュータグラフィックス(CG)で描画して相手に見せる。すなわち各ユーザは、自分が操作する装置上に表示された、会話相手の分身ともいえるキャラクタと会話する状態となる。

30

【0013】

このキャラクタが、本来の会話相手の様子をリアルタイムに反映し、あたかもしゃべっているかのように音声と合致した口の動きをすることにより、実際に相手を見ながら会話しているのと同様の印象を与えることができる。また自分の本当の顔や居場所などを見られたくない場合でも画像を用いた会話を楽しむことができる。またCGならではの効果を加えて娯楽性を高めることもできる。なお同時に会話するユーザは3人以上でもよく、その場合、各装置に複数のキャラクタが表示されてよい。また自分を表すキャラクタを同時に表示するようにしてもよい。

【0014】

情報処理装置10a、10bは、たとえば携帯端末、ゲーム装置、パーソナルコンピュータであってよく、それぞれ会話システムを実現するためのアプリケーションプログラムをロードすることで会話機能を実現する。情報処理装置10aの前面には、カメラ14a、マイクロフォン16a、ディスプレイ18aを備える。情報処理装置10aはそのほか、アプリケーションの起動やその後の各種指示をユーザ12aから受け付けるための入力装置20a、音声を出力するスピーカ22aを備える。情報処理装置10bも同様である。

40

【0015】

同図ではわかりやすさのためにユーザ12aと情報処理装置10a、ユーザ12bと情報処理装置10bとを離して示しているが、同図に示す情報処理装置10a、10bはそれぞれ、ユーザ12a、12bが左右から把持することによって各種操作を行うことので

50

きる携帯可能な端末を想定している。そのため、カメラ 14 a、マイクロフォン 16 a、ディスプレイ 18 a、入力装置 20 a、スピーカ 22 a は、情報処理装置 10 a 本体と一体的に設けられている。

【0016】

一方、カメラ 14 a、マイクロフォン 16 a、ディスプレイ 18 a、入力装置 20 a、スピーカ 22 a のいずれかあるいはすべてが、情報処理装置 10 a 本体と別の筐体を有し、有線あるいは無線で情報処理装置 10 a 本体と接続されていてもよい。たとえば入力装置 20 a はキーボード、マウス、トラックボール、リモートコントローラなどで実現してもよいし、ディスプレイ 18 a 表面や情報処理装置 10 a の外面に設けられたタッチパネルなどの形態でもよい。またディスプレイ 18 a とスピーカ 22 a とを、一般的なテレビによって実現してもよい。

10

【0017】

カメラ 14 a は C C D (Charge Coupled Device) または C M O S (Complementary Metal Oxide Semiconductor) 等の撮像素子を備えたデジタルビデオカメラであり、ユーザ 12 a の映像を撮影し、動画像データを生成する。マイクロフォン 16 a はユーザ 12 a が発する音声を取得して音声データを生成する。ディスプレイ 18 a は例えば液晶ディスプレイ、プラズマディスプレイ、有機 E L ディスプレイ等であり、会話相手を表すキャラクタを表示する。同図の例では、ユーザ 12 a が見るディスプレイ 18 a には相手のユーザ 12 b のキャラクタ 90 が、ユーザ 12 b が見るディスプレイ 18 b にはユーザ 12 a のキャラクタ 92 が表示されている。スピーカ 22 a は会話相手の音声を音響として出力する。

20

【0018】

図 2 は情報処理装置 10 a の内部回路構成を示している。情報処理装置 10 a は、C P U (Central Processing Unit) 32、G P U (Graphics Porcessing Unit) 34、メインメモリ 36 を含む。C P U 32 は、オペレーティングシステムやアプリケーションなどのプログラムに基づいて、信号処理や内部構成要素を制御する。G P U 34 は C P U 32 からの指示に従い画像処理を行い、ディスプレイ 18 a などに出力する。

【0019】

これらの各部は、バス 40 を介して相互に接続されている。バス 40 にはさらに入出力インターフェース 38 が接続される。入出力インターフェース 38 には、U S B や I E E E 1394 などの周辺機器インタフェースや、有線又は無線 L A N、および 3 G や L T E (Long Term Evolution) などのモバイル通信とのネットワークインタフェースからなる通信部 42、ハードディスクドライブや不揮発性メモリなどの記憶部 44、音声データを再生してスピーカ 22 a へ出力する音声処理部 46、カメラ 14 a、マイクロフォン 16 a、入力装置 20 a からそれぞれの入力データを取得する入力部 48、磁気ディスク、光ディスクまたは半導体メモリなどのリムーバブル記録媒体を駆動する記録媒体駆動部 50 が接続される。

30

【0020】

C P U 32 は、記憶部 44 に記憶されているオペレーティングシステムを実行することにより情報処理装置 10 a の全体を制御する。C P U 32 はまた、リムーバブル記録媒体から読み出されてメインメモリ 36 にロードされた、あるいは通信部 42 を介してダウンロードされた各種プログラムを実行する。

40

【0021】

G P U 34 は、ジオメトリトランスファエンジンの機能とレンダリングプロセッサの機能とを有し、C P U 32 からの描画命令に従って描画処理を行い、表示画像を、図示しないフレームバッファに格納する。そしてフレームバッファに格納された表示画像をビデオ信号に変換してディスプレイ 18 a に出力する。あるいは通信部 42 を介して相手の情報処理装置 10 b へ送信する。音声処理部 46 は、通信部 42 を介して相手の情報処理装置 10 b から取得した音声データを C P U 32 からの命令に従って再生しスピーカ 22 a にオーディオ出力する。

50

【 0 0 2 2 】

ネットワーク 8 を介した相手の情報処理装置との通信の確立手順、相手のユーザの音声データ取得、およびオーディオ出力手順については、電話、電話会議、テレビ電話、ボイスチャット、ビデオチャットなどの技術で一般的に用いられている手法のいずれかを適用すればよいため、詳細な説明は省略する。以後、ユーザを表すキャラクタを動作させる手法に主眼を置き説明する。

【 0 0 2 3 】

図 3 は情報処理装置 1 0 a の構成を詳細に示している。同図において、さまざまな処理を行う機能ブロックとして記載される各要素は、ハードウェア的には、CPU、メモリ、その他のLSIで構成することができ、ソフトウェア的には、メモリにロードされたプログラムなどによって実現される。したがって、これらの機能ブロックがハードウェアのみ、ソフトウェアのみ、またはそれらの組合せによっていろいろな形で実現できることは当業者には理解されるところであり、いずれかに限定されるものではない。

10

【 0 0 2 4 】

情報処理装置 1 0 a は、当該装置を操作するユーザ 1 2 a の映像および音声を取得し、それに基づき相手のユーザが操作する情報処理装置 1 0 へ送信するデータを作成する送信データ作成部 6 0、相手のユーザが操作する情報処理装置 1 0 から送信された情報を処理して相手のユーザを表すキャラクタがしゃべる様を表現する受信データ処理部 8 0、ネットワーク 8 を介して必要なデータを送受信する通信部 8 6 を含む。通信部 8 6 はハードウェアとしては図 2 の通信部 4 2 で実現できる。

20

【 0 0 2 5 】

情報処理装置 1 0 a はさらに、基本画像 ID テーブルを格納した基本画像情報記憶部 7 4、表情判定基準を格納した表情判定基準記憶部 7 5、画像データを格納した画像データ記憶部 7 6、およびコマンド ID テーブルを記憶したコマンド情報記憶部 7 8 を含む。以後の説明では、図 1 に示すように情報処理装置 1 0 a が情報処理装置 1 0 b と通信を確立し、それぞれを操作しているユーザ 1 2 a とユーザ 1 2 b が会話するものとする。

【 0 0 2 6 】

このとき、送信データ作成部 6 0 はユーザ 1 2 a の映像および音声のデータを取得し、それに基づき、ユーザ 1 2 a を表すキャラクタの動画パラメータを生成して、音声データと同期させて逐次、通信部 8 6 から相手の情報処理装置 1 0 b へ送信する。ここで動画パラメータとはキャラクタの動きなどを制御するパラメータであり、アニメーションの各フレームに対応するデータ群である。最初にキャラクタのポリゴンセットなど基本のデータを送信しておくことにより、当該動画パラメータを用いて各フレームの画像をその場で作成することができる。具体的な制御パラメータの種類はアニメーションの表示手法によって様々である。なお動画パラメータとして、動画のフレームデータそのものを送信してもよい。

30

【 0 0 2 7 】

さらに、ユーザ 1 2 a の表情が特定のパターンとなったときに、それに対応するコマンドの識別情報を、通信部 8 6 から相手の情報処理装置 1 0 b へ送信する。受信データ処理部 8 0 は、相手の情報処理装置 1 0 b から受信した動画パラメータと音声データを用いて動画生成および表示、音声再生をするとともに、受信したコマンドの識別情報に基づきコマンドを実行する。

40

【 0 0 2 8 】

なお、自分の情報処理装置 1 0 a に、相手のキャラクタとともに自分のキャラクタを表示する態様においては、受信データ処理部 8 0 は、自装置内の送信データ作成部 6 0 が生成した動画パラメータを用いた動画表示を行う。さらにコマンドの内容によっては、自装置内でコマンドを実行する。

【 0 0 2 9 】

送信データ作成部 6 0 は主に CPU 3 2、GPU 3 4、入力部 4 8 によって実現され、ユーザ 1 2 a を表すキャラクタの基本的な画像を特定する基本画像特定部 6 2、カメラ 1

50

4 a が撮影しているユーザ 1 2 a の映像を画像フレームごとに解析して顔認識を行う顔認識部 6 4、顔の所定の部位の形状に基づきユーザ 1 2 a の表情を数値化する表情パラメータ生成部 6 6、各時刻に対しキャラクタの出力モデルを決定するモデル制御部 6 8、出力モデルを含む画像を生成するための動画パラメータを生成する動画パラメータ生成部 7 0、および、ユーザ 1 2 a の表情のパターンに対応するコマンドを特定するコマンド特定部 7 2 を含む。

【0030】

受信データ処理部 8 0 は主に CPU 3 2、GPU 3 4、音声処理部 4 6 によって実現され、相手の情報処理装置 1 0 b から受信した動画パラメータおよび音声データを用いて動画作成および音声再生をしてディスプレイ 1 8 a、スピーカ 2 2 a にそれぞれ出力する再生部 8 2、およびコマンドの識別情報に基づきコマンドを実行するコマンド実行部 8 4 を含む。

10

【0031】

まず送信データ作成部 6 0 の基本画像特定部 6 2 は、基本画像情報記憶部 7 4 に記憶された基本画像 ID テーブルを参照してユーザ 1 2 a の基本画像を特定する。ここで「基本画像」は、ユーザ 1 2 a を表すキャラクタのモデルであり、ユーザごとに設定可能とする。たとえば図示しないキャラクタ作成ツールを別に用意しておき、ユーザは当該ツールに表示された複数種類の頭部形状、顔の各部位、髪型、髪色、衣服、装身具などからそれぞれ好みのものを選択して組み合わせることにより、自分のキャラクタの 3 次元モデルを作成する。背景画像や枠なども選択できるようにしてもよい。このようなツールは、一般的なアプリケーションで実用化されているものを適用できる。

20

【0032】

そのようにユーザ 1 2 a が自分のキャラクタのモデルなどを決定したら、当該モデルを含む基本画像の識別情報とユーザ 1 2 a の識別情報とを対応づけて基本画像 ID テーブルに記録する。基本画像特定部 6 2 は、ユーザ 1 2 a が情報処理装置 1 0 a を起動させたときなどに当該ユーザの識別情報、例えばログイン ID など取得し、それに基づき基本画像 ID テーブルを参照することにより、基本画像の識別情報、例えばモデルの識別番号、またはジオメトリデータの格納先アドレスなどを特定する。

【0033】

一方、ユーザ 1 2 a の識別情報以外の情報、例えばユーザ 1 2 a が会話開始時点で置かれていた状況も用いて基本画像を決定するようにしてもよい。例えば情報処理装置 1 0 a がゲーム装置を兼ねており、ゲーム実行中、またはゲームから切り替えて、他のユーザ 1 2 b と会話を開始するような場合、キャラクタの顔のモデルはユーザ 1 2 a の識別情報によって決定する一方で、当該キャラクタが身につける衣服などは、直前に行っていたゲームのキャラクタの衣装とすることで、会話を盛り上げたり娯楽性を高めたりすることができる。同様に、ユーザ 1 2 a の居場所、時刻、季節などによって衣装や背景画像を決定してもよい。

30

【0034】

いずれの場合も、基本画像とするモデルや背景画像のデータを準備できるという条件のもと、基本画像 ID テーブルにおいて、当該データと、そのいずれかを選択するための属性の識別情報とを対応づけておけばよい。基本画像特定部 6 2 は、会話を開始する際に当該属性の識別情報を取得することにより基本画像を特定する。具体例は後に詳述する。

40

【0035】

顔認識部 6 4 は、カメラ 1 4 a から取得したユーザ 1 2 a の動画像データを逐次解析し、入力画像フレームごとにユーザ 1 2 a の顔認識を行う。具体的には平均的な顔画像とのテンプレートマッチングなどによって、画像中の顔領域、目、鼻、口など顔の各部位の位置および形状を特定し、それぞれにおける特徴点の座標を抽出する。顔認識部 6 4 が行うこれらの処理は、顔認識技術として実用化されている様々な画像解析技術のいずれを適用してもよい。

【0036】

50

表情パラメータ生成部 66 は、顔認識部 64 が抽出した各部位の特徴点の座標から得られるパラメータを、あらかじめ設定した基準値と比較することにより、表情の種類ごとに、表情がなされている度合いを数値化する（以後、これを「表情パラメータ」と呼ぶ）。ここで用いる基準値は、表情判定基準として表情判定基準記憶部 75 に格納しておく。

【0037】

各表情の度合いを数値化するためには、表情判定基準として、当該表情を全くしていないときの値と、最大限しているときの値を設定しておく。例えば口を開けている度合いを数値化する場合、上下の唇の間隔に着目し、平均的な顔において口を閉じているときの間隔を下限値、口を最大に開けているときの間隔を上限値として設定する。そして実際の間隔が下限値から上限値までの範囲のどこに位置するかを確認し、下限値を 0、上限値を 1

10

【0038】

基準値との比較に際しては、顔領域の大きさなどを元に正規化したり、顔の傾きを補正したりする処理を適宜行う。口の開閉のみならず、目の開閉、笑顔、悲しい顔、怒った顔など、複数の表情に対して下限基準値、上限基準値を設定しておくことにより、各表情に対する表情パラメータが入力画像フレームごとに得られる。

【0039】

モデル制御部 68 は、基本画像特定部 62 が特定した基本画像に基づき、画像データ記憶部 76 から、対応するモデルや画像のデータを読み出す。さらに顔認識部 64 が検出した顔領域の傾きや、表情パラメータ生成部 66 が算出した表情パラメータを用いて、入力画像フレームに対応する各時刻におけるキャラクタの出力モデルを生成する。画像データ記憶部 76 が記憶するデータは、ユーザが作成するなどしたキャラクタや衣装の 3次元モデルのジオメトリデータ、背景画像のデータ、3次元グラフィックスの描画に用いる各種パラメータなどを含む。

20

【0040】

ここでキャラクタの 3次元モデルとして、基準となる表情のモデルのほかに、異なる表情を有する複数の表情モデルのデータを準備しておく。そしてモデル制御部 68 が、表情パラメータ生成部 66 から取得した表情パラメータに応じた重みで複数の表情モデルを合成することにより、ユーザの表情に近い表情を有する出力モデルを各時刻に対して生成する。このとき同時に、顔認識部 64 が検出した顔領域の傾きを出力モデルの顔の傾きに反映させる。また体の部分は基本画像に含まれる衣装を着ているようにする。このようにして生成した出力モデルのパラメータは、背景画像のデータとともに動画パラメータ生成部 70 に供給する。

30

【0041】

本実施の形態ではキャラクタがユーザの実際の表情と同様の表情をするのみならず、キャラクタがあたかもしゃべっているように見せることで、より高度に臨場感を演出する。例えば、キャラクタの口の動きをユーザの発話と同期させ、口（唇）の形状をユーザの発音に対応させることができれば、ユーザの音声とキャラクタの画像が合致し、より自然な会話を楽しむことができる。

【0042】

ただしユーザの実際の口の形状を 1フレームごとに詳細に取得してトレースしたり、音声解析によって得られた音に合わせて口の形状を決定したりすると、処理コストが増大してレイテンシが生じやすくなる。その結果、処理リソースや通信帯域に制約があるほどリアルタイムな画像表現が困難となる。そこで本実施の形態では、音量、口の形状、発話期間を総合的に考慮することにより、処理リソースなどに制約がある環境においても、音声と合致してしゃべるキャラクタの画像生成を実現する。

40

【0043】

具体的には、人が発話しているときに現れる代表的な口の形状を抽出、選択してその口の形を有する発声モデルを表情モデルに含め、実際に発声している期間において、時間に対して重みを変化させながら合成する。例えば母音を発音するための典型的な口の形とし

50

て、口を上下または全体的に広げた形（「あ」と発生したときの口）、横に広げた形（「い」と発生したときの口）、すぼめた形（「う」と発生したときの口）を表情モデルとして準備し、各重みを時間変化させながら合成する。

【0044】

選択する口の形状はこれに限らず、言語によっても異なってよい。例えば上下に広げた口、前に突き出した口などでもよい。いずれにしる代表的な音を発声したときの口の形を優先的に選択する。このようにすることで、選択した複数個の口形状の組み合わせが、それぞれの度合いを変えながら時間変化するため、少ないモデル数でも、単純に口がパクパクと開閉しているのではない微妙な動きを容易な演算で演出できる。またこのときの重みに、実際の声量、実際のユーザの口の開き具合を加味することにより、上記のように別の表情の3次元モデルと合成しても、全体的な口の開き具合が、それらの実際の値を反映したものとなる。具体例は後に述べる。

10

【0045】

動画パラメータ生成部70は、キャラクタをアニメーション表示するのに必要が動画パラメータを生成する。例えば時間的に連続する出力モデルをモーフィングしながら描画していくことにより、よりスムーズなアニメーションの動画を生成できる。動画パラメータ生成部70はさらに、生成した動画パラメータを圧縮符号化しながら通信部86に逐次出力する。当該動画パラメータは通信部86で音声データと同期させて相手の情報処理装置10bへ送信する。

【0046】

コマンド特定部72は、顔認識部64が抽出した、顔の各部位の特徴点の座標の時間変化、あるいは当該特徴点から認識できる表情の時間変化を監視し、コマンド情報記憶部78に格納されたコマンドIDテーブルに設定されたパターンに該当する表情の変化が発生したか否かを判定する。ここで設定するパターンは、「5秒以上笑顔とみなされる表情が続いた」など、会話の途中で発生した自然な表情でもよいし、「左目をつぶった後に口を開けて右目をつぶった」など、ユーザがコマンドを発生させるために意識的に行うものでもよい。いずれの場合も、頭部や顔の部位のいずれかの変化、またはその組み合わせと発生順、1つのパターンとして認識する制限時間を設定する。

20

【0047】

そしていずれかのパターンに該当する変化があったと判定されたら、コマンドIDテーブルにおいてそのパターンに対応づけられたコマンドの識別情報を特定する。ここで「コマンド」とは、自分が操作する情報処理装置10aと相手の情報処理装置10bの少なくともいずれかにおいて表示される画像に変化を与える命令である。例えば「5秒以上笑顔とみなされる表情が続いた」場合には自分のキャラクタが踊り出すコマンドを発生させることにより、より効果的にそのときの感情を表現できる。

30

【0048】

「左目をつぶった後に口を開けて右目をつぶった」場合には、意図的に画像に与えたい変化、例えば画面に光のシャワーが流れるように画像を加工するコマンドを発生させる。コマンド特定部72はコマンドIDテーブルから該当コマンドの識別情報を特定すると、当該識別情報を通信部86に出力する。

40

【0049】

受信データ処理部80の再生部82は、相手の情報処理装置10bから送信された動画パラメータおよび音声のデータを通信部86から取得し、フレーム描画、再生処理を行いディスプレイ18aおよびスピーカ22aへ出力する。コマンド実行部84は、相手の情報処理装置10bから送信されたコマンドの識別情報を通信部86から取得しコマンドを実行する。具体的には、コマンド情報記憶部78に格納されたコマンドIDテーブルを参照して、コマンドの識別情報にさらに対応づけられたコマンド実行ファイルをメインメモリ36などから読み出して記述されたスクリプトを実行したりする。

【0050】

このように、相手の情報処理装置10bへ動画パラメータやコマンドの識別情報のみを

50

送信し、表示画像に係る処理の一部を送信先の情報処理装置 10 bで行わせることにより、送信元の情報処理装置 10 aにおける処理の負荷が軽減する。さらに総合的にみて、会話に際して装置間で送受信すべきデータを減らすことができ、データ伝送に必要な帯域を節約することができる。あるいは動画データを送信元で生成してしまい送信先ではそれを再生するのみとしてもよい。これらの態様のいずれかを、使用可能な通信帯域や処理能力によって適応的に選択するようにしてもよい。

【0051】

図4はディスプレイ18aに表示される画像の別の例を示している。この表示画像例94では、相手のキャラクタ90を表示する相手キャラクタウィンドウ96と、自分のキャラクタ92を表示する自キャラクタウィンドウ98とを含む。相手キャラクタウィンドウ96には、相手の情報処理装置10bから送信された、相手のキャラクタ90の動画パラメータによって作成した動画像を出力し、自キャラクタウィンドウ98には、自分のキャラクタ92の動画を出力する。この場合、自分のキャラクタ92の動画パラメータは、受信データ処理部80が、自装置内の送信データ作成部60から直接受け取ることにより生成される。

10

【0052】

またコマンド特定部72は、コマンドIDテーブルに設定されたパターンに該当する表情の変化が発生したと判定したら、対応するコマンドの識別情報を相手の情報処理装置10bに送信するとともに、自装置内のコマンド実行部84にも当該情報を通知する。そしてコマンド実行部84は、自キャラクタウィンドウ98内の画像を対象にコマンドを実行する。

20

【0053】

ただし、自分のキャラクタ92が踊り出すなどキャラクタのアニメーション表示を伴うコマンドを実行する場合は、相手の情報処理装置10bに当該コマンドの識別情報を送信する代わりに、動画パラメータを送信したり、自装置内で生成したアニメーションの動画データを送信したりしてもよい。当該アニメーションを定型的なものとする場合は、あらかじめ、動画パラメータや、操作するユーザのキャラクタのアニメーションを作成して記憶部などに記憶させておいてもよい。

【0054】

コマンド識別情報の代わりに動画データを送信する態様では、相手の情報処理装置10bは、送信された動画データを再生すればよい。そのため、処理の負荷が軽減される。コマンドの識別情報、動画パラメータ、動画データのいずれを送信するかは、コマンドの内容、情報処理装置の処理能力、通信帯域などによって適応的に決定してよい。

30

【0055】

別の例として、相手キャラクタウィンドウ96および自キャラクタウィンドウ98の双方を対象にコマンドを実行してもよい。例えば前述のとおり「5秒以上笑顔とみなされる表情が続いた」場合、自分のキャラクタ92とともに相手のキャラクタ90も踊り出すようにしてもよい。上記のようにコマンド識別情報に代えて動画データを送信する態様では、いったん自分のキャラクタのアニメーションの動画データを相手の情報処理装置10bに送信し、情報処理装置10bから、相手のキャラクタの動画データを返信してもらうことにより、双方のキャラクタが踊り出すように表示させることができる。

40

【0056】

または自分と相手が所定の時間範囲で同じパターンの表情変化を行ったときのみ、コマンドを実行するようにしてもよい。例えば双方のユーザにおいて「5秒以上笑顔とみなされる表情が続いた」ら初めて、自分のキャラクタ92と相手のキャラクタ90が踊り出すようにしてもよい。このような場合、コマンド特定部72がパターンの発生を認識したら、コマンド実行部84にその旨を通知するとともに、相手の情報処理装置10bにコマンドの識別情報、動画パラメータ、動画データのいずれかを送る。コマンド実行部84は、相手の情報処理装置10bから同一コマンドの識別情報または対応する動画パラメータ、動画データが送られてきたときに限り、動画の生成や再生などコマンド実行のための処理

50

を、双方の画像を対象に行う。

【0057】

図5は、基本画像情報記憶部74に格納される基本画像IDテーブルのデータ構造例を示している。基本画像IDテーブル100aは、ログインID欄102、キャラクタ欄104、および背景欄106を含む。ログインID欄102には、事前にユーザごとに付与した識別番号を記録する。キャラクタ欄104、背景欄106にはそれぞれ、上記の通りユーザが事前に作成したキャラクタのモデルを識別する情報、および、選択した背景画像を識別する情報を、ユーザごとに記録する。例えばログインID「0003」のユーザについては、「ネコ1」なるキャラクタを、「背景2」なる画像を背景に表示したものが基本画像となる。

10

【0058】

図6は基本画像IDテーブルのデータ構造例の別の例を示している。基本画像IDテーブル100bは、上記のとおり、ユーザが直前に行っていったゲームのキャラクタの衣装を自分のキャラクタが身につける態様において、図5の基本画像IDテーブル100aと組み合わせて参照される。基本画像IDテーブル100bは、ゲームを識別する情報を記録するゲーム欄108、および、各ゲームにおける主なキャラクタ、またはユーザが選択したキャラクタの衣装のモデルを識別する情報を記録する衣装欄110を含む。

【0059】

例えば上記のユーザが直前に「ゲームA」なるゲームを行っていた場合、「ネコ1」なるモデルのキャラクタは、「戦闘服2」なるモデルの衣装を身につけ、これが基本画像となる。直前に行っていったゲームを識別する情報は、情報処理装置10aの処理履歴などに記録しておく。なお図5の基本画像IDテーブル100aのキャラクタ欄104において識別されるキャラクタのモデルはデフォルトの服を着ていてよく、直前にゲームを行っていたなど特定の条件において、図6の基本画像IDテーブル100bに記録された情報を優先させるようにしてよい。

20

【0060】

図6の基本画像IDテーブル100bのゲーム欄108は上記のとおり、ユーザの居場所、時刻、天気などユーザが置かれている状況を表す属性のいずれに置き換えてもよく、衣装欄110も背景画像の識別情報を記録する欄に置き換えてよい。例えばユーザの居場所を元に背景画像を決定する場合は、「学校」と対応づけて、あらかじめ準備した学校のグラフィックスを背景画像としたり、「自分の部屋」と対応づけて、ユーザが作成した仮想の部屋のグラフィックスを背景画像としたりしてもよい。また、「現在の居場所」と対応づけて、その場でユーザが撮影した風景写真などを背景画像としてもよい。

30

【0061】

このような場合、ユーザが自分の居場所を、「現在の居場所」、「学校」、「自分の部屋」などから選択することにより、基本画像特定部62がそれに対応付けられた背景画像を決定する。居場所によって衣装を変化させてもよい。なお情報処理装置10aの背面に、カメラ14aとは別のカメラ(図示せず)を設けることにより、会話中であってもユーザ12aが見ている風景を随時撮影することができる。そのようにして撮影した画像を背景画像とすることで、実際にユーザが居る場所に、ユーザの分身であるキャラクタが居るといふ、臨場感のある画像を会話相手に見せることができる。

40

【0062】

カメラで撮影しつづけた風景の動画をリアルタイムで背景としてもよい。このようにすると、例えばユーザが散策しているのと同様にキャラクタが散策している様子を相手に見せることができ、会話をより魅力的に演出することができる。時刻や季節などについても、会話を開始する際の時刻や日付を、情報処理装置10aの内部に装備した時計から取得することにより、基本画像の決定に用いることができる。

【0063】

図7は表情判定基準記憶部75に格納される表情判定基準のデータ構造例を示している。表情判定基準120は表情類型122、着目量124、下限基準値126、上限基準値

50

128を対応づけた情報である。表情類型122は、「口開け」、「目閉じ」、「笑顔」など、表情パラメータとしてその度合いを数値化すべき表情の類型である。上述のとおり表情パラメータはキャラクタの表情を決定づける、複数の3次元モデルの合成時の重みに影響を与えるため、キャラクタの表情に含ませたい類型をあらかじめ選択する。また、各類型に対応する3次元モデルを準備する。

【0064】

着目量124は、各表情の度合いを判断する際に着目するパラメータであり、特徴点の座標、分布、複数の特徴点の間隔、初期位置からの変化量など、顔認識部64が抽出した各特徴点の座標から導出できる量である。下限基準値126および上限基準値128はそれぞれ、各表情が全くなされていないと判断するとき、最大限なされていると判断するときの、着目量の具体値である。例えば「口開け」の表情の度合いを判断するとき、「上下唇の間隔」が「 y_1 」であれば口は閉じている、「 y_2 」であれば口が最大限開いている、と判断する。

10

【0065】

「目閉じ」の場合は、「上下まぶたの間隔」が「 y_3 」であれば目は開いている、「 y_4 」であれば目が閉じている、と判断する。目については右目の閉じた度合い、左目の閉じた度合いを個別に判定する。また、笑うと目頭が上がり目尻が下がる一般的な傾向を利用し、「笑顔」の表情の度合いを判断するとき、目頭と目尻の高さの差の、初期値からの変化幅を着目量とする。このとき当該パラメータが「0」であれば全く笑っていない、「 y_5 」であれば最大限笑っている、と判断する。

20

【0066】

なお同図では簡易な表記に止めているが、着目量124、下限基準値126、上限基準値128は実際にはさらに詳細に設定されていてよい。例えば「上下唇の間隔」は実際には、上唇および下唇の中心における特徴点の縦方向の位置を表す y 座標の間隔、などであり、「 y_1 」、「 y_2 」は平均的な顔などに基づき具体的な値をあらかじめ設定する。1つの表情につき複数の条件を設定してもよい。

【0067】

さらに同図の判断基準はあくまで例示であり、パターンマッチング、画像の周波数解析、顔面をメッシュ化したときの形状変化など、表情認識に利用できる様々な手法を用いて条件を設定してもよい。いずれの場合でも、表情判定基準としては、各表情類型が全くなされていない条件と最大限なされているときの条件とを設定しておく。そして表情パラメータ生成部66は、下限基準値を0、上限基準値を1として実際の着目量を正規化することにより、各表情がなされている度合いを数値化する。例えば上下唇の間隔が y_1 と y_2 の間であれば、「口開け」の表情パラメータは「0.5」である。

30

【0068】

図8は、モデル制御部68がキャラクタのモデルを合成する様子を模式的に示している。ここではキャラクタとして牛のモデルが設定されている。画像データ記憶部76には、当該牛のキャラクタの3次元モデルとして、基本モデル130、右目を閉じたモデル132、左目を閉じたモデル134、「あ」と発声した状態のモデル136、「い」と発声した状態のモデル138、「う」と発声した状態のモデル(図示せず)、笑顔のモデル(図示せず)など、複数の表情モデルのデータを画像データ記憶部76に格納しておく。

40

【0069】

そして、表情パラメータ生成部66が導出した表情パラメータに基づき各表情モデルに対して決定した重み w_0 、 w_1 、 w_2 、 w_3 、・・・で重み付けしたうえですべての表情モデルを合成することにより、最終的な出力モデル140を生成する。例えば各モデルのジオメトリデータを用い、GPU34に含まれるパーテクスシェーダによって、次のように頂点ブレンディングを行うことにより合成する。

【0070】

【数 1】

$$o' = o + (p0 - o) \times w0 + (p1 - o) \times w1 + (p2 - o) \times w2 + (p3 - o) \times w3 \\ + (p4 - o) \times w4 + (p5 - o) \times w5$$

【0071】

ここで o' は合成後のモデルの頂点座標、 o は基本モデル130の頂点座標、 $p0$ 、 $p1$ 、 $p2$ 、 $p3$ 、 $p4$ 、 $p5$ はそれぞれ、右目を閉じたモデル132の頂点座標、左目を閉じたモデル134の頂点座標、「あ」と発声した状態のモデル136の頂点座標、「い」と発声した状態のモデル138の頂点座標、「う」と発声した状態のモデルの頂点座標、笑顔のモデルの頂点座標である。

10

【0072】

また $w0$ 、 $w1$ 、 $w2$ 、 $w3$ 、 $w4$ 、 $w5$ はそれぞれ、右目を閉じたモデル132に対する重みパラメータ、左目を閉じたモデル134に対する重み、「あ」と発声した状態のモデル136に対する重み、「い」と発声した状態のモデル138に対する重み、「う」と発声した状態のモデルに対する重み、笑顔のモデルに対する重みであり、0以上1以下の値である。

【0073】

ここで、右目を閉じたモデル132に対する重みパラメータ $w0$ は、表情パラメータのうち、「目閉じ」に対して得られた右目を閉じている度合いをそのまま用いる。同様に、左目を閉じたモデル134に対する重みパラメータ $w1$ は、「目閉じ」に対して得られた左目を閉じている度合いを、笑顔のモデルに対する重み $w5$ は、「笑顔」に対して得られた笑顔の度合いを、そのまま用いる。これにより、例えばユーザが右目を閉じているときは出力モデルも右目を閉じ、ユーザが微笑しているときは出力モデルも微笑した状態を生成できる。

20

【0074】

一方、「あ」と発声した状態のモデル136に対する重み $w2$ 、「い」と発声した状態のモデル138に対する重み $w3$ 、「う」と発声した状態のモデルに対する重み $w4$ については上記のとおり、発声している期間にその値が時間変化するように決定する。例えば次に示すように、 $w2$ 、 $w3$ 、 $w4$ を、異なる周期を有する正弦波の絶対値とする。

30

【0075】

【数 2】

$$w2 = |V \sin(0.7500f)| + m \\ w3 = |2V \sin(0.3750f)| \\ w4 = |2V \sin(0.1875f)|$$

【0076】

ただし $w2$ が1.0を超えたときは $w2 = 1.0$ とする。ここで V はユーザ12aの音量を所定の音量に対して正規化した値であり、マイクロフォン16aから取得した音声データから算出する。 f は現在認識対象となっている入力画像フレームの番号であり、時間軸上の画像フレーム列に0から昇順で与えられる値である。すなわち f が0, 1, 2, ...と進むに従い時間が経過する。 m は、表情パラメータ生成部66が算出した表情パラメータのうち、「口開け」に対して得られた、口を開いている度合いである。

40

【0077】

上記式によれば、音量 V が0のとき、 $w2 = m$ 、 $w3 = w4 = 0$ 、となる。すなわち音量 V が0のときはユーザ12aは発話していないため、しゃべっているように見せる必要はないが、口が少しでも開いていればそれをキャラクタの表情に反映させるため、その度合い m を、「あ」と発声した状態のモデル136に対する重み $w2$ とする。

【0078】

50

声量 V が 0 より大きいときは、認識対象の入力画像フレームが先に進むのに伴う時間経過によって w_2 、 w_3 、 w_4 が異なる周期の正弦波の絶対値で変化する。正弦波の振幅は、声量 V によって変化する。これにより、声量 V が大きいほど全体として大きく開いた口となる。また上式では w_2 、 w_3 、 w_4 の正弦波の周期を、1 倍、2 倍、4 倍と異ならせることにより、多様かつ微妙な口の動きを表現している。 w_3 および w_4 には正弦波にさらに「2」なる係数がかかっているが、このような係数および周期の異ならせ方は、合成後のモデルの口の動きを確認しながら、より自然に見えるように調整して決定してよい。

【0079】

「あ」と発声した状態のモデル 136 に対する重みである w_2 には、声量 V が 0 でないときも常に、口開きの度合い m を加算しておくことにより、声大きいほど、口の開きが大きいほど、「あ」の表情が平均として強く反映されることになり、正弦波の絶対値が 0 近傍にあるときでも口を開けた状態を維持することができる。このように声量と口の開き具合を同時に考慮しつつ、「あ」、「い」、「う」、など代表的な音の発声時の口の形状を有する複数の顔モデルに対する重みを異なる波形で時間変化させることにより、口唇の複雑な動きを表現できるとともに、大まかな動きが音声に合致しているように見せることができる。

10

【0080】

ここで、「え」と発声したときの顔は「い」と発声したときの顔に類似しており、「お」と発声したときの顔は「う」と発声したときの顔と類似しているため、「あ」、「い」、「う」の 3 つのモデルのみを用いても、それを上記のとおり合成することで、人がしゃべるときの様々な口の形を網羅できる。結果として、少ないデータサイズおよび容易な計算で、現実感のある顔の動きを表現できる。

20

【0081】

図 9 は、コマンド情報記憶部 78 に格納されたコマンド ID テーブルのデータ構造例を示している。コマンド ID テーブル 150 は、パターン欄 152、コマンド ID 欄 154、コマンド欄 156 を含む。上述のとおりコマンド特定部 72 は、顔認識部 64 が会話の間中、ユーザ 12a の顔認識処理を行っていることを利用して、顔の各部位の特徴点の時間変化を監視し、パターン欄 152 に設定されたパターンに該当する変化があったか否かを判定する。

【0082】

上述のとおりパターン欄 152 に設定するパターンは、ユーザの自然な表情でもよいし意識的に行わないかぎり発生しないようなものでもよい。後者のパターンについては、ユーザがそれと認識して行う必要があるため、設定されているパターンとそれによって生じる変化をあらかじめユーザに提示しておく。あるいはユーザ自身が設定可能としてもよい。

30

【0083】

コマンド ID 欄 154 およびコマンド欄 156 には、パターン欄 152 に設定したパターンに対応付けて、実行するコマンドのコマンド ID および、当該コマンドを実行するための実体であるコマンド名、実行ファイル名、または関数名などをそれぞれ記録する。パターン欄 152 に設定したパターンは、実際にはさらに、具体的な特徴点の変化を記述したデータに対応づけられていてよく、コマンド特定部 72 は当該記述を参照してもよい。

40

【0084】

また特徴点以外の、一般的な表情認識処理に用いられるパラメータを判定に用いてもよい。コマンド欄 156 に記録するデータは、受信データ処理部 80 のコマンド実行部 84 が、相手の情報処理装置 10b から送信されたコマンド ID に基づきコマンドを実行できるようにしてあればその形態は限定されない。同図の例では、すでに言及したように「5 秒以上笑い続けた」、「左目をつぶった後に口を開けて右目をつぶった」といったパターンのほか、「首を縦振り」、「首を横振り」、「ウィンク 5 回」、「首をかしげる」、といったパターンが設定されている。

【0085】

50

「首を縦振り」した場合、それを「賛成」の意思表示として、当該意思を表現する加工を表示画像に対して行う。たとえばそのようなパターンを発生させたユーザのキャラクタが親指を立てたり拍手をしたりする様を表現する。そのほか背景画像やキャラクタの顔の色を変化させたり、ハートの図形を画面全体に散らせたりするなど、様々な加工が考えられる。いずれの場合も、情報処理装置 10 a は、それを操作するユーザ 12 a が「首を縦振り」したことを検出した場合、コマンド ID 欄 154 から「022」なるコマンド ID を特定し、相手の情報処理装置 10 b に送信する。あるいは対応する動画パラメータやアニメーション動画のデータを送信する。

【0086】

当該コマンド ID を受信した情報処理装置 10 b は、それに基づきコマンド欄 156 から「賛成」なるコマンド実行ファイルを特定し、それを実行することにより、送信元のユーザのキャラクタが表示されている画像に加工を施す。同様に、「首を横振り」した場合、それを「拒否」の意思表示として、「賛成」のときとは対照的な表現を行う。このようにすることで、会話中、外出の誘いなど約束をとりつける場面が発生した場合に、「賛成」や「反対」の意思表示を気軽に行える。このとき、画像上、多少大げさな演出でそれを表現することにより、実際の音声や映像のみでは実現しにくい娯楽性を提供することができる。

【0087】

また「ウィンク 5 回」、すなわち所定の時間範囲において連続して 5 回、片目をつぶる動作がなされた場合は、相手を何かに誘いたい意思表示として、あらかじめ用意しておいた「お誘いアニメーション」を再生して表示する。たとえば図 4 に示したように、自分のキャラクタと相手のキャラクタを同じ画面上に表示するような態様において、誘う側のキャラクタから誘われる側のキャラクタへ招待状が送られるようなアニメーションを表示する。

【0088】

また「首かしげ」、すなわち首を所定の角度以上傾げる動作がなされた場合は、疑問がある意思表示として、情報処理装置 10 a の使用方法などについて記載されたテキストファイルやホームページを別のウィンドウで表示する。例えばコマンド ID テーブル 150 のような表を表示することにより、ユーザがどの動作を行えばよいかわかるようにする。このウィンドウは、そのような動作を行ったユーザが操作する情報処理装置 10 a のディスプレイにのみ表示すればよいため、コマンド ID を相手の情報処理装置 10 b に送信しなくてもよい。

【0089】

以上述べた本実施の形態によれば、ネットワークを介して複数のユーザが会話する会話システムにおいて、相手のユーザの実像に変えてユーザごとに決定したキャラクタを表示させ、実際の音声に応じてリアルタイムで動作させる。このとき、一つのキャラクタにつき異なる表情の複数の 3 次元モデルを準備しておき、ユーザの実際の表情を反映させた重みづけで合成することによりキャラクタの表情を実際の表情に近づける。具体的には、顔認識技術を用いて各表情がなされている度合いを各時刻で数値化し、それに基づき重みを変化させる。

【0090】

このとき、「あ」、「い」、「う」など代表的な音を発声している顔の 3 次元モデルも準備しておき、音量に応じた振幅で独立に時間変化する重みでそれらの 3 次元モデルを合成することにより、口唇の微妙かつ複雑な動きを簡易な計算で表現する。人がしゃべるときの様々な口の動きを、「あ」、「い」、「う」、のモデルのみを用いて擬似的に作り出すため、必要なモデルのデータが少なくすみ、また計算も容易である。

【0091】

さらに「あ」と発声している顔に対する重みには、実際の口の開き度合いをも考慮することで、実際の音声に合致した自然な口の動きを、細かい動き、大まかな動きの双方でリアルに表現することが容易にできる。複数のモデルを合成することでキャラクタの表情が

10

20

30

40

50

多様化するうえ、ユーザの音声、表情に合わせて細かく時間変化させることができるため、少ない処理コストで本当にしゃべっているように見せることができる。

【0092】

またキャラクタの衣装や背景を、それまでユーザが実行していたゲームや居場所など、ユーザが置かれている状況に応じて決定することにより娯楽性を高めることができる。さらに、ユーザの表情の変化を監視しつづけることにより、有限時間においてなされた表情のパターンからコマンドを発生させる。このようにすることで、コントローラを操作するなど手を用いた操作入力を行わずにすみ操作が容易になる。このように表情を用いた操作によって会話中に画像を加工することにより、意思表示などを効果的に演出でき、会話を盛り上げることができる。

10

【0093】

発生させるコマンドについては、その識別情報のみを相手の情報処理装置に送信し、実際のコマンド実行は相手の情報処理装置が担う。またキャラクタをアニメーション表示させるための動画パラメータのみを相手の情報処理装置に送信し、動画の生成は相手の情報処理装置が担う。これにより処理コストを分散させるとともに通信帯域の圧迫を軽減させる。このようにすることで、処理リソースや通信帯域に制約があっても、リアルタイムで複雑な動きをするキャラクタの画像を表示でき、音声とのずれが生じにくい自然な会話システムを実現できる。

【0094】

以上、本発明を実施の形態をもとに説明した。上記実施の形態は例示であり、それらの各構成要素や各処理プロセスの組合せにいろいろな変形例が可能なこと、またそうした変形例も本発明の範囲にあることは当業者に理解されるところである。

20

【0095】

例えば本実施の形態では、直前にユーザが行っていたゲームの衣装をキャラクタに着せる態様を示したが、顔を含めたキャラクタのモデルすべてをゲームのキャラクタに入れ替えるようにしてもよい。この場合も図6に示した基本画像IDテーブル100bの衣装欄110をキャラクタ欄に代え、キャラクタのモデルを識別する情報を設定しておけば、処理手順は本実施の形態と同様に実現することができる。

【符号の説明】


【0096】

1 会話システム、 8 ネットワーク、 10a 情報処理装置、 14a カメラ、 16a マイクロフォン、 18a ディスプレイ、 20a 入力装置、 22a スピーカ、 32 CPU、 34 GPU、 36 メインメモリ、 38 入出力インターフェース、 40 バス、 42 通信部、 44 記憶部、 46 音声処理部、 48 入力部、 50 記録媒体駆動部、 60 送信データ作成部、 62 基本画像特定部、 64 顔認識部、 66 表情パラメータ生成部、 68 モデル制御部、 70 動画パラメータ生成部、 72 コマンド特定部、 74 基本画像情報記憶部、 75 表情判定基準記憶部、 76 画像データ記憶部、 78 コマンド情報記憶部、 80 受信データ処理部、 82 再生部、 84 コマンド実行部、 86 通信部。


30

40


【 図 1 】




【 図 2 】



【 図 3 】



【 図 4 】



【 図 5 】

102 }	104 }	106 }
ログインID	キャラクタ	背景
0003	ネコ1	背景2
0012	ウシ4	背景5
...

100a

【 図 6 】

108 }	110 }
ゲーム	衣装
ゲームA	戦闘服2
ゲームB	制服5
...	...

100b

【 図 7 】

122 }	124 }	126 }	128 }
表情類型	着目量	下限基準値	上限基準値
口開け	上下唇の間隔	$\Delta y1$	$\Delta y2$
目閉じ	上下まぶたの間隔	$\Delta y3$	$\Delta y4$
笑顔	目尻/目頭の変化	0	$\Delta y5$
...


120

【 図 9 】

152 }	154 }	156 }
パターン	コマンドID	コマンド
5秒間笑い続けた	007	踊り出す
左目閉→口開and右目閉	082	光のシャワー
首を縦振り	022	賛成
首を横振り	023	拒否
ウインク5回	009	お誘いアニメーション
首かしげ	034	ヘルプ呼び出し
...

150

【 図 8 】



フロントページの続き

- (72)発明者 金丸 義勝
東京都港区港南1丁目7番1号 株式会社ソニー・コンピュータエンタテインメント内
- (72)発明者 鈴木 章
東京都港区港南1丁目7番1号 株式会社ソニー・コンピュータエンタテインメント内
- (72)発明者 清水 正朗
東京都港区港南1丁目7番1号 株式会社ソニー・コンピュータエンタテインメント内
- (72)発明者 小口 貴弘
東京都港区港南1丁目7番1号 株式会社ソニー・コンピュータエンタテインメント内
- (72)発明者 熊谷 史一
東京都港区港南1丁目7番1号 株式会社ソニー・コンピュータエンタテインメント内

Fターム(参考) 2C001 BA03 BA06 BA07 BB10 BC00 BC05 BC09 CA01 CA06 CA07
CB01 CB02 CB03 CB08 CC03 CC08
5B050 BA08 CA07 CA08 DA01 EA05 EA07 EA10 EA12 EA19 EA24
FA02 FA08 FA10 FA12 FA13
5E501 AB02 BA15 BA17 EA00 EA21 FA15 FA21 FA32