

ベイジアンネットワークを用いた画像解析 による同期信号の判別

Sync Bit Detection Method using Image Analysis with Bayesian Network

中田 豊久 [†] , 伊藤 日出男 ^{††} , 國藤 進 [†] ,

[†] 北陸先端科学技術大学院大学 知識科学研究科 ^{††} 産業技術総合研究所 情報技術研究部門

923-1292 石川県能美市旭台 1-1

Toyohisa NAKADA [†] Hideo ITOH ^{††} and Susumu KUNIFUJI [†]

[†] School of Knowledge Science, Japan Advanced Institute of Science and Technology (JAIST) ^{††}
Information Technology Research Institute, National Institute of Advanced Industrial Science and
Technology (AIST)

1-1 Asahidai Nomi-shi Ishikawa-ken, 923-1292, Japan

要約

位置に基づいた情報サービスを提供するために、赤外線によってユーザの持つ携帯端末に情報を送る研究が行われている。この通信方法の機器構成を大きく変えることなく、ユーザから環境側装置への情報のアップロードを実現するために、反射する赤外線の強さを制御する方法を提案する。環境側ではユーザに提供する情報を赤外線にのせて照射する。携帯端末には赤外線をよく反射する反射材を装着し、その前に液晶を配置する。その液晶を ON/OFF することによって反射材からの反射光の強さを制御する。その反射光の強さの変化は、環境側の赤外線カメラによって認識され、信号とした解釈される。このようなアップロード方法における課題は、液晶 ON/OFF することによる反射光の変化が、携帯端末の位置や向きが変わることによる反射光の変化よりも小さいことである。よって固定化されたしきい値によって画像から液晶 ON/OFF を判定することは困難である。そこで、本研究では動的にしきい値を決定することを提案する。まず携帯端末からある決められた信号パターンの同期信号を送信する。環境側では、その同期信号をベイジアンネットワークによって認識する。ある信号が同期信号であると判定された場合には、その画像から液晶 ON/OFF を分離するしきい値を決定する。この提案手法を、同期信号の認識精度についての従来の機械学習アルゴリズムとの比較を行い、高精度で同期信号を認識できることを明らかとした。

キーワード：ベイジアンネットワーク、反射光通信、赤外線、機械学習

Abstract

In order to realize a position-based service such as transferring useful information to users located in an area, several infrared-used systems have been proposed. Without making significant changes to the configuration, we added an upload function that helps to send user information to the system. A user can send his/her data by using a handheld device that has a reflective sheet and a liquid crystal on its front. The infrared in the system illuminates in the area where the user's device is lying. When the liquid crystal is clear, the reflective infrared magnitude is large. In contrast, the infrared magnitude is comparatively small when the crystal is dark. An infrared camera placed near the infrared projector recognizes the difference in the magnitude. This difference acts as a communication signal from the user to the system. It is necessary to determine the static threshold for distinguishing these two conditions; however, this is difficult because the difference also depends on the position and angle of the user's device. Therefore, the system we have proposed in this research first recognizes the sync bit sent from the user's device by using a Bayesian network. By means of this recognition process, the threshold can then be determined dynamically. Moreover, our experimental results show that the proposed method can easily overcome previously proposed machine learning methods.

Key words : Bayesian Network, Communication, Reflective infred, Machine Learning

1 はじめに

位置に基づいた情報サービスに関する研究開発が近年盛んに行われている。例えば美術館や博物館などで、ある特定の展示物の前にユーザが来ると、その展示物に対する説明といった、その場所に即した情報を提供するサービスである。計算機側からユーザへの情報提供については、Cobit¹⁾ や Everywhere Display Project²⁾ のように様々な方法が提案されている。このようなシステムにおいて、ユーザは提供される情報に対して、例えば受信拒否などの意思表示ができるとよりよいシステムになると考えられる。そこで、このユーザから計算機への通信を、従来の計算機からユーザへの通信機器を大きく変えることなく実現することを本研究では試みる。

計算機からユーザへの情報提供には、近年携帯電話やノートパソコンの近距離通信としてよく利用されている赤外線通信を使用する。これは Cobit のように受信側の機器が簡易になること、及び、プロジェクトターゲットやスピーカなどによって情報を提供するのに比べてプライバシーを考慮できることが利点である。

本論文では、2章でユーザの持つ携帯端末との通信方法とその課題について述べる。次の3章では、通信を実現するために必要な同期信号の認識方法について記述する。本研究では、この認識にベイジアンネットワーク³⁾ を用いた画像解析を提案する。4章では、同期信号の認識精度について従来の分類器との比較を行い、提案手法の優位性を示す。5章では関連研究について言及し、最後の6章でまとめする。

2 赤外線による反射光通信

2.1 機器構成と通信方式

赤外線によるユーザ端末への情報通信システムに、アップロード機能を省電力で付加するために、環境側から送られる赤外線の反射を利用するこことを提案する。携帯端末には赤外線をよく反射する反射材を貼り付け、その前に液晶を配置する。反射材から反射する赤外線と、それ以外から反射する赤外線には大きな光量の差があるため、容易に反射材から

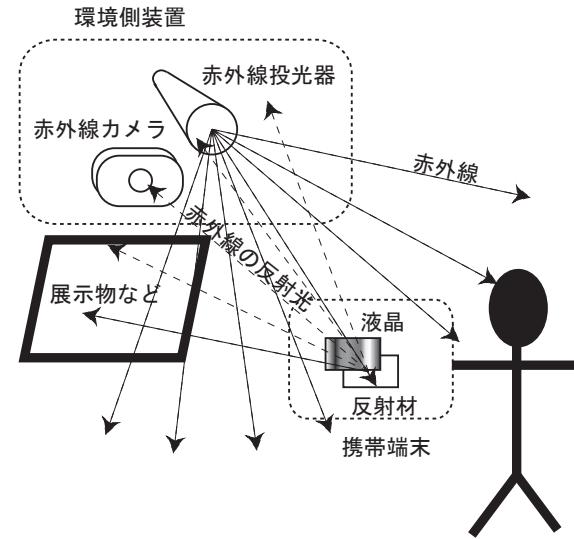


Fig. 1: 赤外線による反射光通信のシステム概要

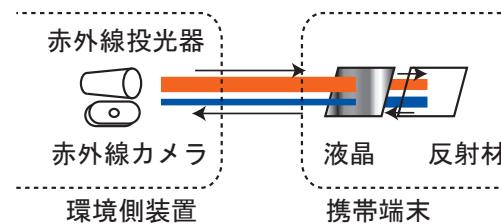


Fig. 2: 赤外線による反射光通信の概要。液晶変調によって反射材から反射する赤外線の強さを制御する。

の反射光を特定することができる。この反射光の強さを、液晶を ON または OFF することによって制御することによって、携帯端末からのデータ送信を実現する。液晶の ON、OFF による反射光の変化は、環境側の赤外線カメラによって認識される。このような方法は、従来の機器構成を大きく変える必要がなく、また、携帯端末が能動的に赤外線を発する必要がないため、電気使用量を小さく抑えることができる事が利点である。システム全体の概要図を Fig.1 に、反射光通信を Fig.2 に示す。

提案する機器構成によりサービスを提供する領域は、使用する赤外線カメラのレンズの仕様により異なるが、おおよそ赤外線カメラの前の 2 ~ 7m 程の距離にある直射日光の当たらない屋内空間を想定している。赤外線カメラを使用するため、他のリモコ



Fig. 3: 赤外線カメラの原画像，2つの携帯端末からの反射光と，実験環境内にある窓からの光が薄く表示されている。

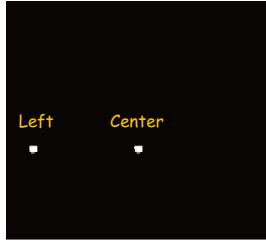


Fig. 4: 携帯端末の抽出手法を適用した後の画像。Left と Center の文字は，説明のために後で付加している。

ンなどの赤外線を使用する機器が携帯端末のすぐ近くにあると通信の妨げになってしまうという制限がある。また，携帯端末を持つユーザは，赤外線カメラの前のサービス可能領域内であれば，どこに居ても通信を行うことができることを目的としている。しかし，ユーザが移動している途中に通信を行うことは想定していない。これは例えば，博物館などで展示物の前で立ち止ったユーザに対して，情報を提供したり，ユーザからの反応を受信したりするサービスをシナリオとして考えているからである。

2.2 反射光通信の課題

Fig.3には，環境側の赤外線カメラによって携帯端末の反射光を撮った原画像を示す。画像上の左側の携帯端末の後ろには窓があり，そこからの光が薄く表示されている。このような原画像は，2.4で示す携帯端末の抽出方法によって処理され，例えばFig.4のような画像となる。図中のLeft や Center という文字は，後述する説明ために付加したもの

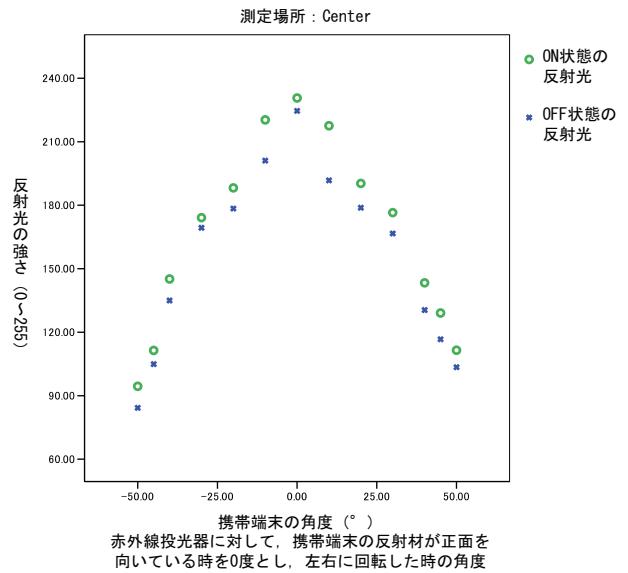


Fig. 5: Centerにおいて携帯端末の向きを変えたときの反射光の強さ。

のである。このFig.4の画像の2つの携帯端末の位置において，携帯端末のカメラに対する向きを変えたときの，反射光の強さの変化をFig.5，6に示す。図の縦軸は，赤外線カメラで受光する携帯端末からの反射光の強さを示す。反射光の強さは0から255の範囲をとり，値が大きいほど明るい。横軸は，最も反射光が強くなる携帯端末が赤外線投光器に対して正面を向いているときを角度0度とし，左右に回転させたときの角度を示す。このときに，右回転を正回転としている。また，図中のON状態とは液晶に電荷をかけずにクリアな状態で反射した赤外線の強さであり，OFF状態の反射光とは，液晶に電荷をかけて暗くした状態の反射光である。どのような位置や角度であってもON状態がOFF状態よりも明るければ，ある固定化されたしきい値によってこの2つの状態を容易に分離できることになる。

しかし例えば，Fig.5の端末の向きが0度のOFF状態と10度のON状態は，0度のOFF状態の方が明るい。また，そのCenter(Fig.5)の0度のOFF状態は，Left(Fig.6)における0度のON状態よりも明るい。液晶による光の遮断は，液晶の分子がさまざまな方向を向いているため，少しの位置や角度の変化でも反射光の強さを大きく変えること

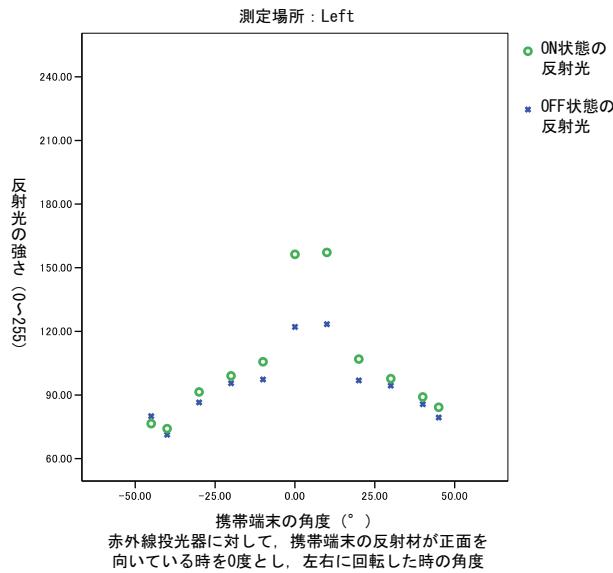


Fig. 6: Leftにおいて携帯端末の向きを変えたときの反射光の強さ .

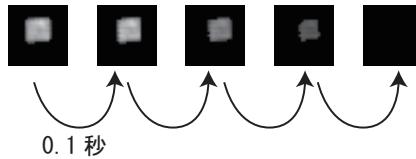


Fig. 7: 約1秒間に1度の速さで回転する携帯端末を0.1秒ごとに撮影した写真 .

がある . しかしこのばらつきがあることを考慮に入れても , 液晶の ON , OFF による反射光の強さの変化は , 携帯端末の位置や向きの変化によって生じる変化に比べて十分に小さいことは明らかである . また , 赤外線カメラから携帯端末までの距離によっても反射光の強さは変化することからも , 固定されたしきい値によって 2 つの状態を分離することは困難である .

また , 画像のみで携帯端末のカメラに対する向きを推測することは困難である . Fig. 7 は , 約 1 秒間に 1 度の速さで携帯端末を回転させ , それを 0.1 秒ごとに赤外線カメラで撮影した図である . 携帯端末に付けられた反射材は長方形の形をしているため , 縦横比が徐々に変化することが期待されるが , 実際にはあまり比率を変えることなく見えなくなってしま

まう . 約 1 秒間に 1 度の回転速度は , 人がゆっくりと回転させることを想定した速さである . このように , たとえゆっくりと回転させた場合でも , 画像から携帯端末の向きを推測することは困難であることが分かる .

2.3 提案する通信方法

2.2 章で示した課題は , ある固定されたしきい値によって液晶 ON , OFF を画像から判定することは困難であることを示している . そこで我々は , 動的にしきい値を設定する方法を提案する . 携帯端末からは送りたいデータを送信する前に , データを送る合図となる信号を送る . このような信号は同期信号と呼ばれ , さまざまな通信方式で利用されている . 受信側では , 赤外線カメラの複数の画像から同期信号の判定を行う . そして同期信号と判定した場合には , 液晶 ON と判定された反射光の平均値と , 液晶 OFF と判定された反射光の平均値の中間値を , 同期信号以降のデータの 0/1 を判定するためのしきい値とする .

受信側からの受信通知やりトライ要求などのプロトコルや , 誤り訂正手法などは , 本システムを使用する環境に合わせて設計してもよいし , 従来の TCP/IP などのプロトコルやチェックサムなどを利用してもよい .

2.4 画像から携帯端末の反射材の抽出

撮影した画像の中の反射材の位置を判別するために , 経験的に決定したある数値以上の輝度¹を持つ画素を , まずクラスタリングする . 本研究で用いたクラスタリング方法は , ある画素の位置が (x,y) とあらわされていた場合には , $(x-4,y-4)$ と $(x+4,y+4)$ を対角線上の頂点とする四角形の中にいる画素は , 隣り合っている画素として同一のクラスターに属させるという方法を採用した . このようにして得られたクラスターのうち , 10 画素以上で構成されるクラスターを反射材と判定した . また , このクラスタリングにより複数の携帯端末からの反射光が抽出された場合には , そのそれぞれからのアップロードを画像から受信する .

¹ 4 章で述べる実験では , 0 から 255 の数値を持つカメラを使用して , この数値を 70 とした .

また、携帯端末の追跡方法については、画像の中の移動するものを認識し、非線形な移動軌跡の予測を行う Condensation 法⁴⁾などの研究成果を、本システムでは利用することを想定している。

3 ベイジアンネットワークによる同期信号のモデル化

3.1 同期信号の判別の概要

同期信号を複数の赤外線カメラの画像から判定する概要について Fig.8 に示す。携帯端末は、自らのタイミングで液晶を ON/OFF している (Fig.8 の左側)。環境側ではその様子を、携帯端末の ON/OFF 間隔よりは速い間隔でカメラのシャッターを切っている (Fig.8 の中央)。そして 2 つの画像から求められる反射光の差分値を累積して同期信号と比較し、類似しているかどうかを判定する (Fig.8 の右側)。その差分値は、撮影環境に依存しないように、-1 から 1 の間の数値に変換してから同期信号と比較する。

同期信号との比較には、差分値をベイジアンネットワークによる同期信号のモデルにセットし、そのモデル適合度によって判定する。同期信号と判定する最小のモデル適合度を設定し、その値以上のモデル適合度を持つ信号は、同期信号であると判定する。その最小のモデル適合度は、教師付き学習によって求める。詳細は、3.6 章で示す。

3.2 同期信号について

同期信号は、多くの液晶の変化が発生するように、1 と 0 が反転する 10101010 (2 進数) の 8 ビットとした。この 8 ビットの中には 1 から 0 に変化するところが 4 回、0 から 1 へ変化するところが 3 回ある。この変化を画像から認識することにより同期信号であるかどうかを判定する。

3.3 画像取得タイミング

携帯端末の液晶変調のタイミングと、環境側で画像を撮影するタイミングは、同期をとれないためタイミングが合ってしまう可能性がある。タイミングが合うと、液晶変調途中の画像を撮影することになる。そのような途中の画像では、2 枚の画像だけ

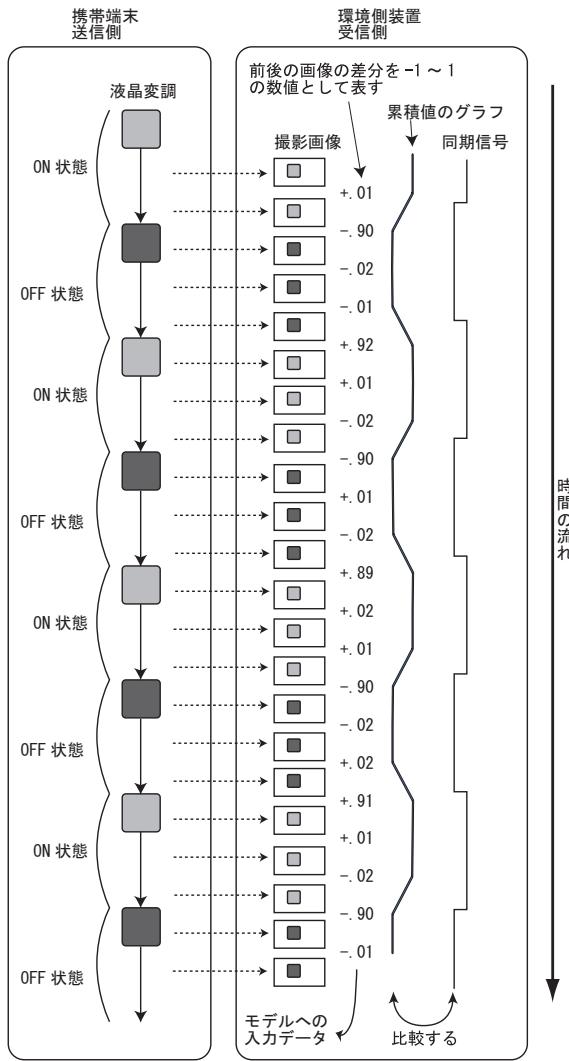


Fig. 8: 携帯端末の液晶変調を撮影して、同期信号とのパターンマッチングを行う。

は液晶変調による反射光の強さの差分を得ることはできない。そこで最大で 3 枚の画像で液晶変調を観測できるようにするために、環境側で画像取得する間隔は、携帯端末の液晶変調間隔の 3 分の 1 とした。

3.4 ベイジアンネットワークによる同期信号の表現

同期信号を 7 回のビット反転が発生する 8 ビットとし、環境側でカメラを撮影する間隔を液晶変調間隔の 3 分の 1 としたため、同期信号を判定す

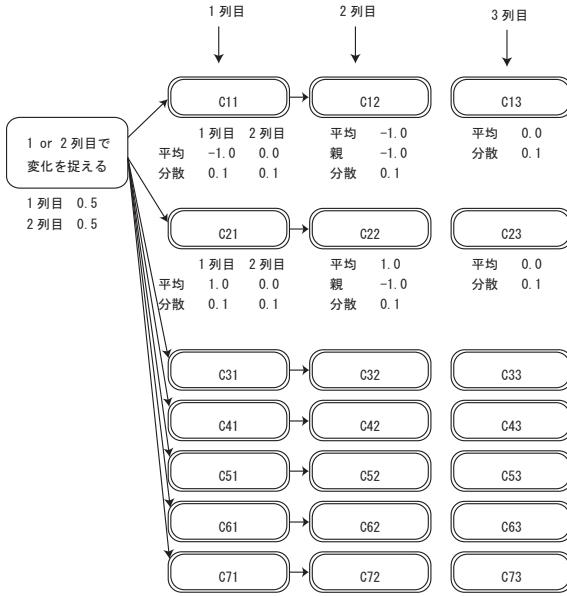


Fig. 9: 同期信号を 10101010 としたときの、ベイジアンネットワークによる表現。

るために必要な差分値は $7*3=21$ 個となる。この 21 個の差分値を 21 個のノードとして表したベイジアンネットワークを Fig.9 に示す。図の単線で書かれたノードは離散的に条件付確率テーブル（以後、CPT）を設定する離散値ノードであり、二重線は正規分布によって CPT を表す連続値ノードである。本研究では、差分値という連続値を表すために連続値ノードを使用している。ノードの下にはそれぞれの CPT を、状態確率の依存関係は矢印で示している。CPT は、離散値ノードの場合には状態とその確率を示すテーブルとして、連続値ノードの場合には正規分布を表すための平均と分散を示している。CPT の示されていない C31 ~ C33, C51 ~ C53, C71 ~ C73 は、C11 ~ C13 の CPT と同じである。同様に、C41 ~ C43, C61 ~ C63 は、C21 ~ C23 と同じ CPT を持つ。このモデルに 21 個の差分値を C11 ~ C73 に順番にセットした時の、それらの値が生起する確率をモデル適合度として使用する。

C11 ~ C73 ノードは、機能を整理するために 7 行 3 列に配置して表示している。1 つの行で、同期信号の 0 から 1 への変化（立上り）もしくは、1 から 0 への変化（立下り）を表している。環境側で取

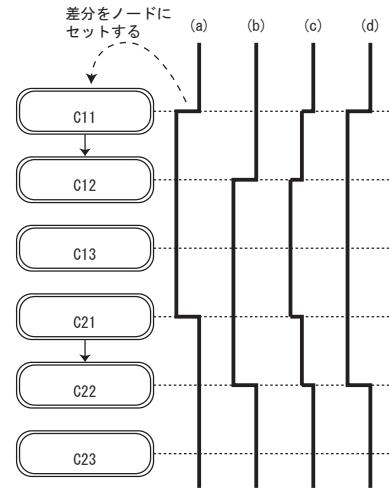


Fig. 10: 差分値をモデルにセットする例。(a), (b) は 1 列目, 2 列目で立下りを観測した同期信号,(c) は液晶変調と画像取得タイミングがあった場合の同期信号,(d) は同期信号ではない。

得する画像の間隔は、携帯端末の液晶変調間隔の 3 分の 1 としたため、立上り、または立下りが起こっている場合には、3 つの差分値の中に必ずその現象が現れているはずである。その 3 つのノードを 1 つかたまりとして 1 段にし、同期信号の中で発生する 7 回の液晶変調を 7 段で表している。

立上り、または立下りは、1 列目のノード、または 2 列目のノード、または 1 列目と 2 列目の 2 つのノードで表すこととしている。例えば 1 列目に立下りを示す差分値がセットされると、2 列目のノードでは立下りを示さない差分値がセットされた方がモデル適合度が高い。Fig.10 の (a) は、同期信号がそのようにベイジアンネットワークにセットされる様子を示している。一方、1 列目にあまり変化のない差分値がセットされた時には、2 列目では立下りの差分値がセットされるとモデル適合度が高くなる (Fig.10 の (b))²。また、携帯端末の状態変化タイミングと画像取得タイミングが一致する場合には、1 列目と 2 列目の 2 つのノードの総和によって立下りを表すことになる (Fig.10 の (c))。このような 1 列目と 2 列目の関係は、ベイジアンネットワーク

² 同じ同期信号を 1 列目で立ち下がるものと 2 列目で立ち下がるものと重複して判定しないように、一度 1 列目で立ち下がる同期信号を受信したら、直後の 2 列目で立ち下がる同期信号は無視する。

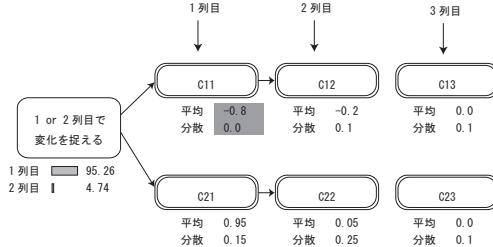


Fig. 11: C11 ノードで立下りを検出したときの、ベイジアンネットワークの確率推論例。網掛け部分は事後確率をセットしたところ。それ以外は確率推論により求められた確率。

の状態確率の依存関係を結ぶことによって実現されている。一方、3列目のノードは、常に0に近い差分値を期待し、そのような値がセットされるとモデル適合度が高くなる。

また、例えば1段目の1列目によって立下りの差分値がセットされた場合には、液晶変調の3分の1の間隔で画像を取得しているため、次の立上りは次の段の同じ1列目で観測されるはずである。このことを「1 or 2列目で変化を捉える」離散値ノードによって表している。このノードは非観測ノードであり、観測値はセットされない。最初にどのノードにも値がセットされていない時には、1列目、2列目で変化を捉える確率は等確率の0.5となっている。そして例えば1段目で1列目において変化を捉える値がセットされれば、「1 or 2列目で変化を捉える」離散値ノードの「1列目」状態の確率は高くなる。そして1段目で1列目において立下りを示す差分値がセットされているにもかかわらず、2段目では2列目で立上りの差分値がセットされた場合には(Fig.10の(d))「1 or 2列目で変化を捉える」ノードとの不整合が起こり、モデル適合度は下がる。このようなFig.10の(d)のような信号は、液晶変調の間隔が仕様よりも大きいため同期信号ではないからである。

3.5 モデル適用例

Fig.11に最初のC11ノードに立下りの差分値がセットされたときのモデルの適用例を示す。C11ノードに立下りと思われる-0.8をセットして確率推

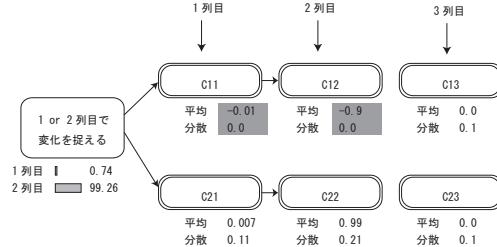


Fig. 12: C12 ノードで立下りを検出したときの、ベイジアンネットワークの確率推論例。網掛け部分は事後確率をセットしたところ。それ以外は確率推論により求められた確率。

論を実施すると、2列目のノードは-0.2という比較的無変化な状態を期待していることが分かる。このノードにセットされる値は、この値に近いほどモデル適合度は高くなる。そしてこのときの「1 or 2列目で変化を捉える」ノードは、1列目で変化を捉えることを期待した値となっている。

Fig.12では、C11ノードは無変化、C12ノードに立下りの差分値をセットしたときの例を示す。Fig.11とは逆に、「1 or 2列目で変化を捉える」は2列目の変化を期待する値となっている。

3.6 モデル適合度から同期信号の判定

画像から得られる入力データをモデルの各ノードにセットすると、その入力データがそのモデルにおいて生起する確率を求めることができる。本研究では、その確率をモデルへの適合度としている。同期信号と判定する適合度の最小値は、予め同期信号であるか、そうでないかという教師データを含めた信号データから学習する。

この学習は次のようにして行う。教師付き学習データをモデルに適合し、同期信号ではないデータの最大適合度と、その適合度を越える同期信号の最小適合度との中間値を、同期信号と判定する最小値とする。これは、すべての同期信号ではない信号のモデル適合度の上に同期信号と判定する最小適合度を設定するため、同期信号であっても同期信号でないと判定する失敗よりも、同期信号でないと判定する失敗をできるだけ回避しようとした方策と言える。4章で使用する評価

指標でいうならば，Recall よりも Precision を優先した方策である。

本研究における Precision とは，受信側で同期信号であると判定したデータのうち，本当に同期信号であった割合である。Precision を優先した理由としては，Precision が低い場合には，チェックサムなどによる通信エラーの検出を行うとした場合に，通信効率が著しく悪くなるからである。チェックサムによるエラー検出は，送信データ（以後，データ部と呼ぶ）からある値（以後，チェック部と呼ぶ）を求め，チェック部をデータ部の後ろに付けて送信する。そして受信側では，同じアルゴリズムでチェック部を計算し，送られてきたチェック部と同じであれば通信エラーは発生していないとする方法である。しかし通信エラーが頻繁に発生する場合には，データ部とチェック部に同時にエラーが発生し，まれにエラーが発生していないと誤認することがある。これを回避するためには，チェック部に使用するビット数を増やす必要がある。我々のシミュレーションでは，Precision が約 0.93 の時には 1 バイトのデータ部に対して 4 バイトのチェック部がなければエラーを見逃してしまうことがあることがわかった。

一方，Precision と共に利用される指標として，Recall がある。本研究では，携帯端末が送信した同期信号のうち，受信側で同期信号であると判定できた割合を Recall は示す。Precision ではなくこの Recall が低い場合には，受信側ではデータが送られたことに気付かないということを意味している。この場合には受信側からの受信成功通知がないなどの判断から，送信側で再送を行えばよい。環境側から携帯端末へのダウンロードは，アップロードよりも高品質で行うことができるため，環境側で受信したにもかかわらず，その応答が携帯端末に届かない可能性は少ない。よって例えば Recall が 0.93 であれば，ほぼ 0.93 の確率で携帯端末は環境側からの受信成功通知を受けることになる。Precision が約 0.93 のときには，1 バイトのデータを送るために 4 バイトのチェックサムを付けて，合計で 5 バイトが必要であった。しかもその 5 バイトは，通信エラーを検出できることを保証するだけであり，通信エラーが発生した時にはもう一度 5 バイトを送らなければいけない。一方，Recall が 0.93 のときには，

例えば 5 回連続して環境側が気付かない可能性は，約 0.00000168 という低い確率となる。

以上のことより，Recall よりも Precision を優先した方が通信の効率を向上できると考え，モデル適合度の決定方法に採用した。

4 実験と考察

4.1 実験環境

実験で使用した機器は，携帯端末は 1.5 秒間隔で液晶変調を行う。通信速度は約 0.67bps である。環境側の赤外線カメラは，画素数 512*480，画素のピット数 8 ピット，焦点距離 12mm，F 値 1.4 のものを用い，液晶変調間隔の 3 分の 1 の 0.5 秒に 1 枚の画像を取得した。実験は，直射日光が当たらない，蛍光灯による一般的なオフィスの照明環境で行った。そして反射材を抽出するためのクラスタリングに使用する最小の反射光の強さは，70 とした。

実験データは，ランダムな位置と角度で人が手に持った携帯端末から送られる同期信号とそうでない信号を，赤外線カメラで撮影することによって取得した。撮影範囲は，赤外線カメラの前の約 2m ~ 7m の範囲で行った。

4.2 実験概要

実機を使用して収集したデータに，同期信号であるかどうかを示す教師データを付加し，提案する手法と他のよく知られている機械学習アルゴリズム（分類器）との比較を行う。合計で 1185 個のモデルへの入力データを作成した。そのうち同期信号であるものは，48 個である。

実験は 10 ホールドのクロスバリデーションによって行う。まず 1185 個のデータから，10 個の学習データと試験データのセットを作成する。提案手法を含めて分類器は，学習データで学習を行い，試験データで分類精度を計る。分類器への入力は 21 個の差分値，出力は同期信号であるかないかである。提案する手法の学習は，同期信号と判定するモデルの最低適合度を求めることがある。比較する分類器の学習は，そのそれぞれの分類器の仕様による。

提案手法は Java 言語により実装し， Bayesian Network の部分には開発支援ツールである Hugin⁵⁾を使用した．

4.3 評価指標

分類器の評価は， Precision と Recall の調和平均である F measure を使用する．それぞれの計算式については，式(1)～(3)に示す．本研究における Precision とは，受信側で同期信号であると判定したデータのうち，本当に同期信号であった割合である．一方， Recall は，携帯端末が送信した同期信号のうち，受信側で同期信号であると判定できた割合を示す．

この評価値を 10 ホールドのクロスバリデーションによって算出する．

Precision =

$$\frac{\text{同期信号を同期信号と判定した数}}{\text{同期信号と判定した数}} \quad (1)$$

Recall =

$$\frac{\text{同期信号を同期信号と判定した数}}{\text{同期信号の数}} \quad (2)$$

$$\begin{aligned} \text{F measure} &= 2 * \text{Precision} * \text{Recall} \\ &/ (\text{Precision} + \text{Recall}) \end{aligned} \quad (3)$$

4.4 比較した分類器

提案手法と比較した分類器の概要を， Table.1 に示す．入力データは提案手法と同じように，携帯端末からの反射光の差分値を時系列に 21 個並べた数値を使用する．出力として，同期信号であるかないと判定する．

これらの分類器は時系列データを扱えるものではない．つまり入力データはすべて独立した値であるとして取り扱う．よって，本研究で使用する 21 個の差分値の入力データは， 1 つの属性の値がある差分値，別の属性の値がまた別の差分値，というように差分値間の依存関係を考慮せずに学習する．

比較する分類器の実装には Java 言語を使用したデータマイニングツールである Weka¹⁵⁾ を使用した．そして各分類器のパラメータは， Weka のデフォルトを使用した．

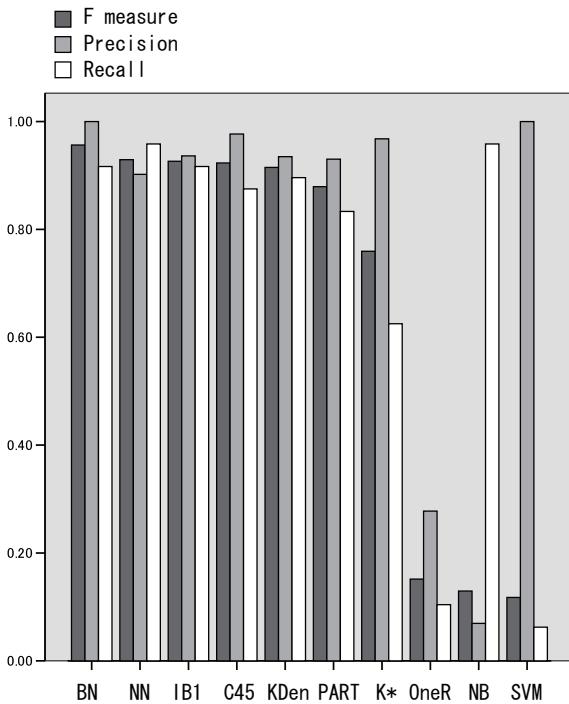


Fig. 13: 各分類器と提案手法の分類精度実験の結果．分類器は，左から F measure の値が大きい順に並んでいる．

4.5 結果

Fig.13に結果を示す．F measure を評価値として提案手法が最もよい精度を示した．また， Precision を優先した方策を採用しているため， 100% の Precision を得ることができている．

4.6 考察

提案手法が他の分類器よりも良い結果を示したことは， 1 つは，パラメータチューニングに原因がある．提案手法以外は， Weka のデフォルトパラメータを使用しているため，より適したパラメータを見つかれば，さらに良い結果を示すことが考えられる．

また提案手法には，より多くの本システムに対する情報が実装されていることも要因の 1 つであると考える．それは，携帯端末からの同期信号を正確にベイジアンネットワークによってモデル化したことである．他の分類器は，学習データのみの情報から

Table 1: 比較した各分類器について

名称	図中の名称	概要
提案手法	BN	ベイジアンネットワークによって同期信号を表現する .
Neural Network ⁶⁾	NN	脳の神経ネットワークを模擬した分類器 .
IB1 ⁷⁾	IB1	最も類似する教師データの正 / 負によって判断する分類器 .
C4.5 ⁸⁾	C4.5	数値データを扱うデシジョンツリーアルゴリズム .
Kernel Density ⁹⁾	KDen	核関数に基づくノンパラメトリックな確率密度関数の推定 .
PART ¹⁰⁾	PART	枝切りしないデシジョンツリーアルゴリズム .
K* ¹¹⁾	K*	インスタンスベースと統計的な手法を混合した分類器 .
OneR ¹²⁾	OneR	1 つのルールのみを作成するデシジョンツリーアルゴリズム .
Naive Bayes ¹³⁾	NB	正 / 負をデータ属性の条件付確率で表した分類器 .
Support Vector Machine ¹⁴⁾	SVM	別次元に写像したデータを線形分離する分類器 .

同期信号を判別していることに対して、提案手法には事前知識が含まれている。このことが、よい結果を示した原因と考える。

比較した分類器は、入力データの取り扱いによって 2 つに分類できる。C4.5 や PART などのデシジョンツリーアルゴリズムは、入力の 21 個の差分値を総合的に見て判断するわけではない。例えば n 番目のデータが x 以上の値の時には同期信号である、といったように、1 つづつの入力に対してルールを適用しようとする。一方、Kernel Density, Support Vector Machine, Neural Network などは、それぞれの値の重みつき総和のような総合値によって同期信号であるかどうかを判断する。提案した手法も後者に入る。直感的には後者の方が、本課題に対しては適していると思われる。しかし C4.5 が Kernel Density よりもよい成績を収めていることから、学習データに偏りがあった可能性が指摘される。C4.5 が作る分類規則は、この課題に対しては汎用的な規則であるとは言いかたい。そこで今後は、より多くのデータによって評価する必要があると思われる。

5 関連研究

画像認識にベイズ法を適用する研究には様々なものがある（例えば¹⁶⁾）。この 1 つの目的は、学習データが十分に得られないときに、事前確率や主観

確率と呼ばれる学習データ以外の知識を学習に含めて、精度を向上させることである。我々の研究もこれと同じ立場をとる。予め機器についての知識をベイジアンネットワークに表現し、それを同期信号の分類に使用することによって他の分類器に比べてよい結果を残すことができた。

ベイジアンネットワークは、ユーザのモデル化などに利用されている。例えばマイクロソフトは、Notification platform¹⁷⁾ というユーザの現在状態を考慮した通知システムを構築している。ある人が他の人に連絡を取りたいときに、連絡をしたいユーザの緊急度だけでなく、連絡を受ける人の状態をも考慮して、電話などで割り込むか、またはメールなどで非同期に通知するかを判断するシステムである。この連絡の受信者の状況推定にベイジアンネットワークを使用している。このような状況推定に利用するベイジアンネットワークは、主に観測事象から未観測事象の状態確率を推定する確率推論を利用する。一方、我々はベイジアンネットワークを 1 つの確率分布として取り扱っている。これは隠れマルコフモデルによる音声認識¹⁸⁾ と同様である。隠れマルコフモデルではなくベイジアンネットワークを利用する利点は、隠れマルコフモデルよりも表現力が豊かであることと、豊富な開発支援ツールが整備されていることである。

ベイジアンネットワークの構造をデータから学習する K2 アルゴリズム¹⁹⁾ などがある。しかし本研

究ではベイジアンネットワークの構造や CPT については学習から求めていない。通信機器の構成から事前に構築してパターンマッチングに使用している。

6 おわりに

赤外線の反射光の強さを液晶によって制御することで実現する通信を提案した。環境側では携帯端末の液晶 ON/OFF の状態を、赤外線カメラによって捉えた反射光の強さの変化によって認識する。通信を開始する合図となる同期信号の認識に、ベイジアンネットワークを用いた。この方法を、従来の機械学習手法と比較して最も精度が高いことを確認した。

今後は、通信速度の改善や実環境での利用を想定した実験を進め、また実運用を想定したコスト面などについても検討していきたい。

参考文献

- 1) Takuichi Nishimura, Hideo Itoh, Yoshiyuki Nakamura, Yoshinobu Yamamoto, and Hideyuki Nakashima: "A Compact Battery-Less Information Terminal for Real World Interaction", PERVASIVE 2004, Springer LNCS 3001, pp.124-139, (2004).
- 2) C. Pinhanez and M. Podlaseck: "To Frame or Not to Frame: The Role and Design of Frameless Displays in Ubiquitous Applications", Proceedings of Ubicomp'05, pp.340-357, (2005).
- 3) 本村陽一, 岩崎弘利: "ベイジアンネットワーク技術 ユーザ・顧客のモデル化と不確実性推論", 東京電機大学出版局, (2006).
- 4) Michael Isard and Andrew Blake: "CONDENSATION – conditional density propagation for visual tracking, International Journal of Computer Vision, Vol.29, No.1, pp.5-28, (1998).
- 5) Finn Verner Jensen: "An Introduction to Bayesian Networks", Springer, (1997).
- 6) D. Michie, D. J. Spiegelhalter, C. C. Taylor (eds): "Machine Learning, Neural and Statistical Classification", Prentice Hall, (1994).
- 7) Aha, D. and D. Kibler: "Instance-based learning algorithms", Machine Learning, vol.6, pp. 37-66, (1991).
- 8) Ross Quinlan, "C4.5: Programs for Machine Learning, Morgan Kaufmann Publishers", San Mateo, CA, (1993).
- 9) M.P. Wand, M.C. Jones: "Kernel Smoothing", Chapman & Hall/CRC, (1994).
- 10) Eibe Frank and Ian H. Witten, "Generating Accurate Rule Sets Without Global Optimization. In Shavlik, J., ed.", Machine Learning: Proceedings of the Fifteenth International Conference, Morgan Kaufmann Publishers, San Francisco, CA, (1998).
- 11) John, G. Cleary and Leonard, E. Trigg, "K*: An Instance-based Learner Using an Entropic Distance Measure", Proceedings of the 12th International Conference on Machine learning, pp. 108-114, (1995).
- 12) R.C. Holte: "Very simple classification rules perform well on most commonly used datasets", Machine Learning, Vol. 11, pp. 63-91, (1993).
- 13) George H. John and Pat Langley: "Estimating Continuous Distributions in Bayesian Classifiers", Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence. pp. 338-345. Morgan Kaufmann, San Mateo, (1995).
- 14) J. Platt: "Fast Training of Support Vector Machines using Sequential Minimal Optimization", Advances in Kernel Methods: Support Vector Learning, B. Scholkopf, C. Burges, and A. Smola, eds., MIT Press, (1998).

- 15) Ian H. Witten and Eibe Frank: "Data Mining: Practical machine learning tools and techniques", 2nd Edition, Morgan Kaufmann, San Francisco, (2005).
- 16) Li Fei-Fei, Rob Fergus, and Pietro Perona: "A Bayesian Approach to Unsupervised One-Shot Learning of Object Categories", Proceedings of the Ninth IEEE International Conference on Computer Vision - Volume 2, pp.1134-1141, (2003).
- 17) E. Horvitz, C. M. Kadie, T. Paek, D. Hovel: "Models of Attention in Computing and Communications: From Principles to Applications", Communications of the ACM 46(3):52-59, March, (2003).
- 18) Rabiner, L. and Juang, B.: "Foundations of Speech Recognition", Prentice Hall PTR (1993).
- 19) Gregory F. Cooper: "The computational complexity of probabilistic inference using Bayesian belief networks", Artificial Intelligence, Vol.42, pp.393-405, (1990).