

乳牛の歩行映像解析による軽度蹄病の検出

砂川 翔哉¹ 大倉 史生¹ 生熊 沙絢¹ 中田 健² 八木 康史¹

概要: 酪農業界において戸数あたりの乳牛の増加に伴い、酪農家の乳牛管理の負担が増加している。乳牛の管理が行き届かずに疾病にかかることは生乳の質・量の悪化につながるため、疾病の初期段階での自動検出を実現することが喫緊の課題である。乳牛の疾病は外見的特徴に現れるものが多数あり、そのうち最も重要かつ重大な疾病の一つは蹄の傷や壊死を伴う蹄病である。蹄病の診断には、背形状と歩容（歩き方）の観察により蹄の健康度を5段階（スコア1：健康、スコア5：重度の蹄病）で表す跛行スコアが用いられる。従来、映像解析に基づき抽出された背形状（背線の曲がり方）を特徴としてスコアの推定やクラス分類を自動で行う手法が提案されている。しかし、背形状特徴は、歩容と比較して軽度の蹄病を発見する目的に適していないことが知られている。そのため、本研究では距離画像センサにより取得された歩行中の乳牛の三次元形状から乳牛の歩容特徴を抽出し、軽度の蹄病を発見するシステムを構築する。本稿では、本研究で用いる歩容特徴により、跛行スコア1（健康）とスコア2（軽度の蹄病）以上の牛を99%の精度で分離可能であることを示す。

キーワード: 酪農、乳牛、跛行、歩容解析、サポートベクターマシン

1. はじめに

酪農業において、乳牛の日々の健康管理を適切に行うことが極めて重要である。しかし近年、酪農従事者の高齢化 [1] と酪農家あたりの乳牛飼育数の増加 [2,3] により、酪農家にかかる負担が増加している。酪農家は掃除、給餌、搾乳等の作業に追われ、健康管理のために乳牛を観察する機会が減少している。健康管理を怠ると乳牛の病気の発見が遅れ、生乳の品質や生産効率が悪化することにより、経済的損失を被る。

特に乳牛の廃用の原因となる三大疾病の一つである蹄病に関連する蹄の健康維持は、乳牛の健康管理において重要である。蹄に異常が生じると、乳牛は痛みにより歩行を嫌がる。これにより、蹄に血液が循環せず、状態はさらに悪化し、乳牛の運動量が減少する。その結果、蹄のみならず全身の様々な病気やトラブルの原因となる [4]。最悪の場合、起立もままならないため、食糧摂取が困難になり産乳量も減少し、死に至ることもある [5]。

獣医師や酪農家は経験的な指標に基づき、目視や触診によって乳牛の健康状態を計測している。躯体と体脂肪のバランスを見ることで肥満または痩せすぎの状態を知ること

ができるボディコンディションスコア（以降、BCSと呼ぶ）、ルーメン（第一胃）窩と呼ばれる牛の左側のへこみ具合で餌を適切に食べているかを知ることができるルーメンフィルスコア（以降、RFSと呼ぶ）、蹄病に罹患しているかを歩き方や立ち姿から調べる跛行スコアがその代表例である [6]。RFSは数時間単位、BCSと跛行スコアは数週間単位で変化するとされている。

本研究では、健康状態管理のためのスコアのうち、蹄の健康維持に直接関連する跛行スコアについて取り扱う。乳牛の蹄に異常がある場合、背中の曲がり具合と歩容に変化が表れ、蹄の状態が好ましくなければ、背中が曲がるとともに歩幅が小さくなったり脚を庇ったりする様子が観察できる。跛行スコアは、これらの特徴変化によりスコア1からスコア5の5段階に振り分けられる [5]。跛行スコアが低いほど乳牛の蹄は健康で、跛行スコアが高いほど蹄の状態が好ましくないことを示す。図1(a)に跛行スコア1の乳牛、図1(b)に跛行スコア3の乳牛を示す。

健康状態管理のためのスコアリングは酪農家の目視による観察で行われており、獣医師が定期的に診断することもある。しかし、前述のように酪農家は日々の作業に追われているため観察回数が少なく、病気を見落とす可能性がある。獣医師が日常的に診断することは、コストと獣医師の数を考えると非現実的である。そのため情報技術を用いた日常的な診断は、乳牛管理の省力化および高品質な乳牛生

¹ 大阪大学
Osaka University

² 酪農学園大学
Rakuno Gakuen University



(a) 跛行スコア 1 の乳牛 (b) 跛行スコア 3 の乳牛

図 1 跛行スコアによる背中中の曲がり具合の違い [6]

産を実現するために必要である。跛行スコア推定に関して、乳牛の産乳量と食料摂取量、体重の変化を日々観察することで病気の兆候を発見する研究 [7, 8] が行われており、一般的な牛舎設備があればセンサ取り付けが不要である一方、直接的に跛行の特徴（背形状や歩行の様子）を観測するわけではないため、高精度に跛行を発見することは困難である。また、4つの独立した体重計を用いることで脚をかばっている兆候を発見する研究 [9, 10]、3軸加速度センサを用いて起立時や歩行時のバランスを測定することで蹄病を発見する研究 [11-14] なども行われている。しかし、これらの手法は、特殊な体重計や加速度センサを牛舎や牛体に取り付ける必要がある。

近年安価かつ牛体への取り付けが必要なく、牛舎への設置が容易なカメラを用いた健康状態の推定が注目されている。画像処理に基づく跛行スコアの推定手法として、牛体の真横から撮影された映像から推定された背中中の曲がり具合 [15, 16] のほか、歩幅や着地タイミング [17-19] を算出することで跛行スコアを推定する研究が行われている。しかし、牛体の横からの撮影は、遠距離の場合牛舎の構造上柵が障害となり、近距離の場合は乳牛によるカメラへの接触が起こるため、実用上困難を伴う。

カメラ設置位置の問題を解決するため、3次元形状が取得可能な距離画像センサを用いた3次元画像処理がしばしば用いられる [20-23]。実用上、距離画像センサは乳牛の歩行路の真上または斜めに設置される。距離画像から自動で背形状を求め、頭の下がり具合も考慮した独自の指標により跛行スコアを推定する研究 [20, 21] や、背形状特徴に加えて他のセンサから取得した産乳量や活動記録の情報を付加することで、より精度を向上させる研究 [22, 23] が行われている。これまで、3次元画像処理に基づく手法には背形状特徴が用いられ、跛行の有無、すなわち比較的健康的な跛行スコア 2 以下と明確に異常があると判断できるスコア 3 以上との分類を重視してきた。しかし、一般的に、牛舎内にスコア 2 の乳牛が増加した場合、専門家は対策を講じる必要がある。そのため、スコア 2 の乳牛の発見、つまり跛行の早期発見が重要である。

従来、背形状に加えて目視での跛行の判断要素とされてきた歩容は、背形状と比較し跛行の早期発見に適していると言われている [6]。そのため、本研究では、距離画像セン




図 2 牛舎の見取り図



図 3 Kinect の設置位置

サにより撮影された画像列を入力として、歩行中の乳牛の3次元形状から乳牛の歩容特徴を抽出し、軽度の蹄病を発見するシステムを構築する。本報告では、軽度蹄病の検出のためのデータベース構築及び歩容に基づく特徴量を提案し、構築されたデータベースを用いた実験により跛行スコア 1（健康）とスコア 2（軽度の蹄病）以上の乳牛を 99%の精度で分離可能であることを示す。

2. スコア付き乳牛データベースの構築

酪農学園大学の協力の下、牛舎内に撮影機器を取り付けて乳牛を撮影し、その映像を加工して乳牛の個体 ID、撮影時刻、位置合わせされた 1 歩行周期分の乳牛の点群データ、跛行スコアをそれぞれ対応付けたデータベースを構築した。

2.1 撮影環境

乳牛の撮影は牛舎内に Kinect for Windows v2（以降、Kinect と呼ぶ）を取り付けて行った。本研究では、カラー画像と距離画像を撮影している。Kinect の仕様を表 1 に示す。牛舎内で、乳牛は図 2 に示す矢印方向に移動する。Kinect は図 3 のように乳牛を上から撮影できる位置に取り付けられている。この位置に設置することで、乳牛の歩行を 1 周期程度撮影するとともに、背中に現れる背中中の湾曲度合と歩容の特徴を得る。また、乳牛は Kinect の画角内に進入する前に必ず搾乳ロボットを通過する。搾乳ロボットでは、搾乳作業を行った乳牛の個体識別番号と日時を自動で記録するため、このデータを用いることで乳牛の個体識別番号と日時を撮影データと対応づける。以上の環境におけるカラー・距離画像（図 4(a)、図 4(b) 参照）の撮影期間は 2015 年 9 月 28 日～2015 年 10 月 27 日で、撮影回数は 1581 回である。

2.2 歩行データの選別

本稿では歩容特徴を使用するため、乳牛が 1 歩行周期以上歩いているデータが必要となる。しかし、すべての場面において乳牛が 1 歩行周期以上歩いているとは限らないた

表 1 Kinect の諸元

撮影データ	画像サイズ [ピクセル]	フレームレート
RGB	512 × 424	30 fps
距離	1920 × 1080	30 fps



(a) 乳牛のカラー画像 (b) 乳牛の距離画像

図 4 Kinect による撮影画像例

め、1 歩行周期以上存在する場面を選別する必要がある。本研究では、歩容特徴による跛行スコア分類の精度評価を目的とし、手作業で映像選別を行った。具体的には Kinect で撮影された距離画像 (図 4(b) 参照) を目視で確認し、乳牛が静止した場面や人などの障害物が映り込んだ場面を取り除き、1 歩行周期以上存在する場面を選別する。また、選別後に乳牛の距離画像列が歩行 1 周期分になるように手動で調整する。歩行 1 周期分の 3 次元点群データは、乳牛の歩行 1 周期分の距離画像列から得られる。図 4(b) では、画像中の黒画素が測定不能点で、黒に近いほど近景、白に近いほど遠景の点を表す。

2.3 位置合わせ済み三次元点群シーケンスの生成

2.3.1 背景差分

背景差分は、カラー画像に比ベシルエット抽出が容易な距離画像を用いて行う。まず、取得した距離画像において前景の事後確率を求める。Kinect は投光した赤外線パルスが反射して戻ってくるまでの時間を計算することで距離情報を取得する。赤外線パルスが乱反射した場合などは未観測となることがあるため、それぞれの画素について

- 距離データが観測される確率 $P(O=1, X=B)$
- 画素値 (距離データ) の平均 μ
- 画素値の分散 σ^2

を背景学習のデータとした。距離データが観測される確率は、入力画像の数を N 、それぞれの画素の観測された回数を M とおくと、

$$P(O=1, X=B) = \frac{M}{N} \quad (1)$$

と表せる。ここで、観測・未観測を表す事象を $O = \{0, 1\}$ とする。 $O = 1$ が観測の事象、 $O = 0$ が未観測の事象を表す。 X は $X = \{F, B\}$ としており、 $X = F$ が前景である事象、 $X = B$ が背景である事象を表す。画素の平均および分散はそれぞれの画素の観測されたデータについて計算したものである。具体的には、平均値 μ と分散 σ^2 はそれぞれ以下のように計算される。

$$\mu = \frac{1}{M} \sum_{m=1}^M d_m \quad (2)$$




図 5 二値化画像

図 6 マスク画像

$$\sigma^2 = \frac{1}{M} \sum_{m=1}^M (d_m - \mu)^2 \quad (3)$$

ここで d_m は対象画素における m 番目に観測された距離データである。また、対象画素において一度も距離データが観測されなかった場合は計算されないことに注意されたい。差分は以下の式を用いて各画素の前景である事後確率をベイズの定理を用いて求めた。ここで、 $P(X=F)$ 、 $P(X=B)$ は 0.5 と定義する。入力画像において距離が未観測の場合は、

$$P(X=F|O=0) = \frac{P(O=0|X=F)}{P(O=0|X=B) + P(O=0|X=F)} \quad (4)$$

距離が観測できた場合は

$$P(X=F|O=1, d) = \frac{p(d|X=F)P(O=1|X=F)}{p(d|X=B)P(O=1|X=B) + p(d|X=F)P(O=1|X=F)} \quad (5)$$

として計算する。 d は入力距離である。前景が計測できる確率 $P(O|X=F)$ は、観測・未観測どちらになる確率が高くなるのかは不明なので、観測できる場合と未観測になる確率を同等であると、

$$P(O|X=F) = 0.5 \quad (6)$$

と仮定している。背景が計測できた確率 $P(O|X=B)$ は背景学習で求めた値である。背景学習の際に d が計測できる確率 $P(d|X=B)$ は確率密度関数を用いて計算する。

$$p(d|X=B) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(d-\mu)^2}{2\sigma^2}\right\} \quad (7)$$

μ は背景学習で得たそれぞれの画素における画素の平均、 σ^2 は分散を表す。入力画像で d が計測できる確率 $p(d|X=F)$ を

$$p(d|X=F) = \frac{1}{N_d} \quad (8)$$

と定義する。Kinect の場合は、階調値が 8,000 であるため $N_d = 8000$ とする。また、前景である事後確率を閾値を設けて二値化したものが図 5 である。距離画像中の各画素の 3 次元座標を求め、3 次元点群に変換し、先ほどの二値化後の画像を用いてマスクすることにより、前景に該当する 3 次元点群を得る。この 3 次元点群の最大クラスターを乳牛の 3 次元点群として用いる。

2.3.2 3 次元位置合わせ

様々な距離・角度から撮影されたデータの視点の正規化を行う。歩行時に撮影した距離画像列から生成した 3 次元点群を位置合わせすることで、同じ位置で歩行する点群に

変換する。本研究では、剛体を仮定とした二つの点群の位置合わせを行う ICP (Iterative Closest Point) [24] アルゴリズムを用いて点群の位置合わせを行った。

まず、1シーケンスのそれぞれの3次元点群の重心と長軸を合わせ、点群の位置合わせの初期値とする。次に、図7に示すように、ICP アルゴリズムは位置合わせを行う二つの点群の差が大きいと正しく位置合わせすることができないため、隣接する二つのフレームで ICP アルゴリズムを用いて位置合わせを行う。1シーケンスの中心のフレームを基本となるフレームとして定義する。隣接フレームで位置合わせした点群を基本フレームと位置合わせする。図8に位置合わせ後の点群を示す。

点群の位置合わせを行う際に、3次元座標系に対して以下の制約を設ける。

- 3次元座標系の第1軸を牛の体の長軸と対応させ、この軸を距離画像センサの位置と方向から算出した地面と平行に保つ。
- 第2軸を地面と垂直方向に定義する。
- 第3軸を他の2軸と垂直となるように定義する。

本研究で Kinect を設置した牛舎では乳牛が16頭飼育されている。ここから、個体毎に異なる日・時間に撮影されたものを含む歩行1周期の点群データから、延べ523頭分のデータベースを構築した。

2.4 跛行スコアの付与方法

跛行スコアは酪農学園大学にて獣医師が定期的に診断することによって得られたデータで、搾乳ロボットの日時データと紐付けられる形で管理されている。跛行スコアは1章でも述べたように5段階で評価され、スコア1の乳牛は蹄の状態が最も健康で、スコアが大きくなるにつれて蹄の状態も悪化する。獣医師による跛行スコアの診断は2015年9月28日、10月12日、11月2日の3日であり、歩行中の乳牛の点群データ取得頻度と比較し少ない。そのため、本研究では跛行スコアについては同個体間の診断結果を時間方向に線形補間し、日付ごとに小数点第2位まで含む跛行スコアを改めて算出し、各乳牛の歩行1周期分の3次元点群データに付与する。元々診断されていない撮影日時の跛行スコアに関して時間方向の線形補間を行うことは、跛行スコアが急激に変化するのではなく、緩やかに変化するということを仮定している。これは1章で述べたように跛行スコアが数日単位ではなく数週間単位で変化する指標であるためである。ここまでの操作で登録されたデータベースの内容を表2にまとめる。ただし、時間方向の線形補間によって生成された跛行スコアについては四捨五入して表記している。

3. 軽度蹄病検出のためのスコア分離

本研究では、乳牛の軽度跛行検出のために乳牛の1歩行

周期分の3次元点群データを用いる。跛行にみられる歩容の変化を特徴量化するため、位置合わせ済み点群系列を用いて歩容特徴(平均シルエット)を生成する。また、比較対象として従来手法で用いられる背形状の情報を含む特徴(平均深度)をあわせて生成する。得られた特徴量は次元数が大きい主成分分析を行って次元数を削減し、獣医師の診断による跛行スコアをラベルとして、スコア1およびスコア2以上を分離するように学習を行い、軽度蹄病検出を行う。

3.1 本研究で用いる特徴量

本研究では乳牛1歩行周期分の3次元点群データを仮想カメラで撮影し特徴量を抽出する。仮想カメラで撮影するにあたって仮想カメラの撮影位置を考慮する必要が生じる。人間の個人認証における歩容特徴の抽出過程では、脚部等の観測のために人物の真横や前面からの映像が広く用いられる。一方、本研究における撮影のように、斜め上や真上からの撮影では、脚部の欠損が多く発生する。健康な乳牛と比較すると、跛行を有する乳牛では跛行のある脚を庇うことで、その脚の真上部分が大きく沈む傾向が観察できる。また、背中動きだけではなく、脚を庇う動作により体が左右に振れるといった人間においても観察できるような特徴が表れる。そこで、本研究では、乳牛の歩行時に体や背中の動きに表れる特徴を利用するため、位置合わせ済み3次元点群列(図8)を牛体の真上から再投影する(図9参照)。投影された深度画像列を用い、本研究では以下の2特徴を算出する。

3.1.1 平均シルエット

平均シルエットは乳牛の歩行時の体の揺れを考慮した歩容特徴量で、各画素における観測確率を特徴として用いた。画素の観測された回数を M 、1歩行周期のフレーム数を N とおくと、各画素の特徴量は以下の式(1)のように定義される。

$$p = \frac{M}{N} \quad (9)$$

平均シルエットを可視化したものを図10に示す。画像中で白いもの程観測回数が多く、黒いものほど観測回数が少ないことを表す。なお、本特徴は人間の歩容認証に広く用いられる平均シルエット特徴[25]と同一の特徴である。

3.1.2 平均深度

平均深度は乳牛の背中の曲がり具合を含めた背形状全体

表2 3次元点群データを有する乳牛の跛行スコア分布

跛行スコア	乳牛の延べ撮影回数	乳牛の個体数
1	394	14
2	104	4
3	15	1
4	10	1
5	0	0




図 7 点群の位置合わせ




図 8 位置合わせ後の点群




図 9 乳牛点群の再投影



図 10 平均シルエット特徴



図 11 平均深度特徴




図 12 平均シルエットの主成分分析により得られた主成分パターンを表す基底画像




図 13 平均深度の主成分分析により得られた主成分パターンを表す基底画像

を考慮した背形状特徴量で、撮影した深度データのそれぞれの画素で以下のように計算したものである。深度の平均 μ を以下の式 (2) ように定義する。

$$\mu = \frac{1}{M} \sum_{m=1}^M d_m \quad (10)$$

ここで d_m は対象画素における m 番目に観測された深度データである。また、各画素において一度も深度データが観測されなかった場合は計算されない。平均深度を可視化したものを図 11 に示す。画像中で黒いものほど、仮想カメラに対して近く、白いものほど仮想カメラに対して遠いことを表す。青色部分は未観測を表す。なお、本特徴は 3 次元歩容特徴のひとつである Depth-based gait feature [26] の直流成分と類似した特徴である。

3.2 主成分分析

各特徴量が持つ情報は冗長であるため、主成分分析

(Principal Component Analysis: PCA) を行って次元を削減する。

各特徴量について 1 シーケンスあたり 840×525 の画素があり、算出した特徴量に対する画像の冗長性を低減し効率の良い学習を行うため、本研究では 128×80 の大きさにリサイズを行い、2 章で構築したデータセットから算出された各特徴量の分散に基づき主成分の基底を算出する。平均シルエット、平均深度の各特徴から算出された主成分から生成された 128×80 画素の基底画像をそれぞれ図 12、13 に示す。第 1 主成分の基底画像は元のシーケンス群に共通するような乳牛の輪郭を表していることがわかる。

本研究では、学習時の次元削減を目的として、各特徴量から算出された主成分の合計寄与率が 80% 以上となるように、分散の大きな主成分から順に選択した特徴量を学習に用いた。その結果、平均シルエットでは 12 次元、平均深度では 54 次元の主成分が選択された。

3.3 跛行診断結果の学習手法

本研究では、軽度蹄病の検出にあたってサポートベクターマシン (Support Vector Machine: SVM) [27] を用いて学習を行い検出器を作成する。SVM は2クラスのパターン認識のための手法であるため、あらかじめ正解のデータとしてデータセットの各シーケンスを跛行の有無に関して2クラスに分類する必要がある。ここでの2クラスは、跛行診断結果を線形補間し四捨五入した跛行スコアが1のもの延べ394シーケンスと跛行スコアが2以上のもの延べ129シーケンスとなるように分類を行った。サポートベクターマシンは様々なカーネル関数と組み合わせることで非線形識別器に拡張することが可能である。本研究では算出した特徴量が線形的に分離可能なのかそれとも困難なのかを判定するために線形カーネルとRBFカーネルを利用し比較を行う。

4. 実験と考察

提案特徴量およびデータセットを用い、SVM 識別器に各特徴と跛行診断結果を学習させ、その識別器の性能評価を行った。本章では、性能評価及び考察を行う。

4.1 性能評価

平均シルエット特徴を用いた識別器と平均深度特徴を用いた識別器の性能評価を行うために、それぞれの識別器に対し交差検定を行った。交差検定は以下の手順で行った。

- (1) 全16頭の個体に対して1個体分の全データを抜き出す。
- (2) 取り除いた個体を除く他の個体のデータを入力としてサポートベクターマシンの学習を行う。
- (3) 取り除いた個体を評価データとして入力する。
- (4) 1~3の手順をすべての個体に対して行う。

また、SVMにおけるコストパラメータ、カーネルパラメータについては、学習ごとに最適化せずそれぞれ1で固定した。平均シルエット特徴、平均深度特徴を用いた場合の交差検定における混同行列 (表3参照) を表4,5,6,7に示す。また、本研究で作成したデータベースに従来研究 [28] の背形状特徴 \mathcal{F}_{bck} を適用した場合の混同行列を表8に示す。表9に、各手法による識別精度をまとめる。ここで、識別精度は以下のように、正しくポジティブなクラスとネガティブのクラスに分類できた割合として定義される。

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (11)$$

表4,5,6,7は、線形カーネルによるSVMと比較してRBFカーネルによるSVMを用いた場合の方が精度がよく、線形カーネルによるSVMでは分離しきれないことを示している。また、表9ではRBFカーネルによるSVMではどちらの特徴に関しても90%以上の分類精度があり、平均シルエット特徴に関しては100%近くの分類精度となってい

ることを示している。線形カーネルを用いた場合の平均シルエットと平均深度を比較すると、スコア2以上の分類結果に関しては平均深度の方が良く、背形状特徴は比較的線形分離しやすいことがわかる。

従来研究の背形状特徴 \mathcal{F}_{bck} とRBFカーネルによるSVMを用いた平均シルエット特徴を比較すると、表5,8,9からわかるように、スコア1、スコア2以上の分類、また分類精度の全てに関して平均シルエット特徴が良い結果となった。特に、スコア2以上の分類では、背形状特徴による分類結果が5割程度の精度となっており背形状特徴は蹄病の早期発見には適していないことがわかる。一方、歩容特徴による分類結果は9割以上の精度となっており、歩容特徴が蹄病の早期発見に適した特徴であることが示された。

4.2 考察

提案特徴量についての考察 ここでは、実験において最も

表3 混同行列

	予測が正例	予測が負例
実例が正例	True Positive(TP)	False Negative(FN)
実例が負例	False Positive(FP)	True Negative(TN)

表4 平均シルエット (線形)

	スコア1	>スコア2	合計	正解割合
スコア1	368	26	394	93.4%
>スコア2	121	8	129	6.2%

表5 平均シルエット (RBF)

	スコア1	>スコア2	合計	正解割合
スコア1	394	0	394	100%
>スコア2	4	125	129	96.9%

表6 平均深度 (線形)

	スコア1	>スコア2	合計	正解割合
スコア1	352	42	394	89.3%
>スコア2	100	29	129	22.5%

表7 平均深度 (RBF)

	スコア1	>スコア2	合計	正解割合
スコア1	394	0	394	100%
>スコア2	40	89	129	69.0%

表8 従来特徴 \mathcal{F}_{bck} による線形回帰結果

	スコア1	>スコア2	合計	正解割合
スコア1	380	14	394	96.4%
>スコア2	68	61	129	47.3%

表9 各手法による識別精度

平均シルエット (線形)	71.9%
平均シルエット (RBF)	99.2%
平均深度 (線形)	72.8%
平均深度 (RBF)	92.4%
従来特徴 (線形回帰)	84.3%





図 14 スコアごとの第 3 主成分のヒストグラム

高い識別精度となった平均シルエット特徴について考察する。本研究では、PCA により平均シルエットを 12 次元に圧縮した。その中で、クラス分布が比較的分離している第 3 主成分 (図 12(c)) について述べる。図 14 は、第 3 主成分の主成分スコアをクラスごとにヒストグラム化したものである。第 3 主成分は乳牛の輪郭付近の部分を含まない頭部部分と臀部部分に現れる特徴を示しており、図 14 からスコア 1 の場合、比較的大きな値をとり、スコア 2 以上の場合は比較的小きな値をとることがわかる。図 14 中のスコア 1 で最も多いビンに属する個体の平均シルエット画像を図 15、スコア 2 で最も多いビンに属する個体の平均シルエット画像を図 15 に示す。これらの画像について第 3 主成分を考慮すると、スコア 1 の個体については体全体が明確に表れており、第 3 主成分が大きくなった。これは健康な個体で、しっかりと歩行し体の部分的な揺れが表れないためだと考えられる。スコア 2 以上の個体については、主に臀部の方が左右に揺れることにより不明瞭で第 3 主成分が小さくなった。跛行を起こして不健康な個体の場合、脚を引きずるなどの余分な動作を起こすことで歩行中に体が揺れるためだと考えられる。実際、健康な個体は滑らかな脚運びと体全体の左右の動揺が観察でき、跛行を有する個体はゆっくりとぎこちない脚運びをしながら、跛行を有する脚部分を大きく左右に振っている様子が観察できる。以上のことから、部分的な左右の動揺によるシルエットの欠如は第 3 主成分に大きく表れていることがわかる。図 14 に示すように第 3 主成分のみで高精度な分離を実現することはできないが、残り 11 次元の主成分も作用することで非線形なクラス分離を可能にしたと考えられる。

スコア誤判定についての考察 平均シルエット特徴を用いた非線形分離 (表 5 参照) において、スコア 1 と判定されたスコア 2 以上の個体について考察する。誤ってスコア 1 と判定されたスコア 2 以上の 4 シーケンスはすべて同一個体によるものであった。誤判定要因の一つとして、跛行診断結果の線形補間による実際の跛行スコアとの相違が考えられる。しかし、表 10 のように実際の診断日と観測日



(a) スコア 1 の個体 (b) スコア 2 の個体

図 15 各スコアの平均シルエット特徴

の間隔が狭く、その影響は限定的である可能性が高い。一方、跛行診断は主観的評価によるものなので、診断結果そのものが間違っている可能性は否定できない。実際に当該個体と他の健康な個体の撮影データを比較したところ、当該個体は健康な個体に比べわずかに負傷しているような様子が見られた。誤ってスコア 1 と判定されたスコア 2 以上の 4 シーケンスがすべて同一個体であったことを考慮すると、当該個体に観察できる歩容特徴が健康な個体によく観察できるような歩容特徴を有し、スコア 1 と判定された際には、跛行による歩行障害の特徴よりも健康な個体によく観察できるような特徴が強く表れたと考えられる。

5. おわりに

本研究では、獣医師らによって付与された跛行スコアと歩行 1 周期分の乳牛の 3 次元点群データを対応付けたデータベースを構築した。構築されたデータベースに基づき軽度蹄病を発見するため、乳牛の歩容に基づく特徴量の提案および抽出を行った。分類精度の評価では歩容特徴、背形状特徴に対して、それぞれ学習とテストに同個体を含まないように跛行識別器を作成し交差検定を行った。学習手法としては、乳牛に対する跛行診断結果を時間方向に線形補間したスコアが 1 (健康) であるか、スコアが 2 (軽度跛行を含む跛行) 以上であるかの 2 値問題に帰着させサポートベクターマシンを用いた。

実験の結果、本研究で提案した歩容特徴による分類精度は 99.2% となり、上方からの深度観測に基づく背形状特徴と従来手法による背形状特徴を上回った。跛行スコアは蹄の状態を表す指標で専門家による診断の際には主に背形状が観察されるが、軽度跛行の診断には歩容が重要となるといわれており、本研究における実験結果は、これらの知見を反映したものであると考えられる。一方、跛行診断にお

表 10 特定個体の診断日と観測日の関係

診断日	観測日	診断結果・線形補間結果
9/28		2
	9/30	2
	10/1	2
	10/6	2
10/12		2
	10/14	2
11/2		1

いて背形状の観察も重要な要素であるため、背形状特徴、歩容特徴双方を組み合わせることで更なる精度の向上が見込まれる。

今後の課題としては、特徴量の時系列変化についての解析を行うことで跛行の前兆となるような特徴を発見し跛行予防につなげること、また BCS や RFS などの他の健康指標の推定などが挙げられる。

謝辞

本研究は JSPS 科学研究費補助金 研究活動スタート支援 15H06362 の助成を受けたものです。

参考文献

- [1] 一般社団法人中央酪農会議. 平成 23 年度酪農全国基礎調査.
- [2] 農林水産省. 畜産統計, 2015.
- [3] 一般社団法人 J ミルク. 乳用牛飼養戸数・頭数 (全国), 2015.
- [4] 公益社団法人日本装蹄協同会. <http://sosakutei.jrao.ne.jp/sakutei-knowledge/>.
- [5] Jan Hulsen, 監訳中田健, 及川伸. Hooves 蹄の健康管理のための実践ガイド (COW SIGNALS). デーリイマン社, 2008.
- [6] Jan Hulsen, 監訳中田健. COW SIGNALS 乳牛の管理のため実践ガイド. デーリイマン社, 2008.
- [7] T.F. Borderas, A. Fournier, J. Rushen, and A.M.B. De Passille. Effect of lameness on dairy cows' visits to automatic milking systems. *Can. J. Anim. Sci.*, Vol. 88, pp. 1–8, 2008.
- [8] R.M. de Mol, G. Andre, E.J.B. Bleumer, J.T.N. van der Werf, Y. de Haas, and C.G. van Reenen. Applicability of day-to-day variation in behavior for the automated detection of lameness in dairy cows. *J. Dairy Sci.*, Vol. 96, pp. 3703–3712, 2013.
- [9] N. Chapinal, A.M. de Passille, J. Rushen, and S. Wagner. Automated methods for detecting lameness and measuring analgesia in dairy cattle. *J. Dairy Sci.*, Vol. 93, pp. 2007–2013, 2010.
- [10] M.E. Pastell and M. Kujala. A probabilistic neural network model for lameness detection. *J. Dairy Sci.*, Vol. 90, pp. 2283–2292, 2007.
- [11] N. Blackie, J. Amory, E. Bleach, and J. Scaife. The effect of lameness on lying behaviour of zero grazed holstein dairy cattle. *Appl. Anim. Behav. Sci.*, Vol. 134, pp. 85–91, 2011.
- [12] K. Ito, M.A.G. von Keyserlingk, S.J. LeBlanc, and D.M. Weary. Lying behavior as an indicator of lameness in dairy cows. *J. Dairy Sci.*, Vol. 93, pp. 3553–3560, 2010.
- [13] C. Kamphuis, E. Frank, J.K. Burke, G.A. Verkerk, and J.G. Jago. Applying additive logistic regression to data derived from sensors monitoring behavioral and physiological characteristics of dairy cows to detect lameness. *J. Dairy Sci.*, Vol. 96, pp. 7043–7053, 2013.
- [14] M. Pastell, J. Tiisanen, M. Hakojarvi, and L. Hanninen. A wireless accelerometer system with wavelet analysis for assessing lameness in cattle. *Biosyst. Eng.*, Vol. 104, pp. 545–551, 2009.
- [15] A. Poursaberi, C. Bahr, A. Pluk, A. Van Nuffel, and D. Berckmans. Realtime automatic lameness detection based on back posture extraction in dairy cattle: shape analysis of cow with image processing techniques. *Comput. Electron. Agr.*, Vol. 74, pp. 110–119, 2010.
- [16] S. Viazzi, C. Bahr, A. Schlageter-Tello, T. Van Hertem, E.C.B. Romanini, A. Pluk, I. Halachmi, K. Lokhorst, and D. Berckmans. Analysis of individual classification of lameness using automatic measurement of back posture in dairy cattle. *J. Dairy Sci.*, Vol. 96, pp. 257–266, 2013.
- [17] N. Blackie, E. Bleach, and J. Scaife. Impact of lameness on gait characteristics and lying behaviour of zero grazed dairy cattle in early lactation. *Appl. Anim. Behav. Sci.*, Vol. 129, pp. 67–73, 2011.
- [18] A. Pluk, C. Bahr, A. Poursaberi, W. Maertens, A. van Nuffel, and D. Berckmans. Automatic measurement of touch and release angles of the fetlock joint for lameness detection in dairy cattle using vision techniques. *J. Dairy Sci.*, Vol. 95, pp. 1738–1748, 2012.
- [19] X.Y. Song, T. Leroy, E. Vranken, W. Maertens, B. Sonck, and D. Berckmans. Automatic detection of lameness in dairy cattle - vision-based trackway analysis in cow's locomotion. *Comput. Electron. Agr.*, Vol. 64, pp. 39–44, 2008.
- [20] T. Van Hertem, S. Viazzi, M. Steensels, E. Maltz, A. Antler, V. Alchanatis, A. Schlageter-Tello, K. Lokhorst, E.C.B. Romanini, C. Bahr, D. Berckmans, and I. Halachmi. Automatic lameness detection based on consecutive 3D-video recordings. *Biosyst. Eng.*, Vol. 119, pp. 108–116, 2014.
- [21] S. Viazzi, C. Bahr, T. Van Hertem, A. Schlageter-Tello, E.C.B. Romanini, I. Halachmi, C. Lokhorst, and D. Berckmans. Comparison of a three-dimensional and two-dimensional camera system for automated measurement of back posture in dairy cows. *Comput. Electron. Agr.*, Vol. 100, pp. 139–147, 2014.
- [22] T. Van Hertem, M. Steensels, S. Viazzi, E.C.B. Romanini, C. Bahr, D. Berckmans, A. Schlageter-Tello, K. Lokhorst, E. Maltz, and I. Halachmi. Improving a computer vision lameness detection system by adding behaviour and performance measures. In *Proc. Int. Conf. of Agricultural Engineering*, 2014.
- [23] T. Van Hertem, C. Bahr, A. Schlageter-Tello, S. Viazzi, M. Steensels, E.C.B. Romanini, C. Lokhorst, E. Maltz, I. Halachmi, and D. Berckmans. Lameness detection in dairy cattle: single predictor v. multivariate analysis of image-based posture processing and behaviour and performance sensing. *animal*, Vol. 10, pp. 1525–1532, 2015.
- [24] A.V. Segal, D. Haehnel, and S. Thrun. Generalized-ICP. In *Proc. Robotics: Science and Systems*, Vol. 2, 2009.
- [25] Z. Liu and S. Sarkar. Simplest representation yet for gait recognition: Averaged silhouette. In *Proc. 17th Int. Conf. on Pattern Recognition*, Vol. 4, pp. 211–214, 2004.
- [26] H. Nakajima, I. Mitsugami, and Y. Yagi. Depth-based gait feature representation. *IPSS Trans. on Computer Vision and Applications*, Vol. 5, pp. 94–98, 2013.
- [27] B.E. Boser, I.M. Guyon, and V.N. Vapnik. A training algorithm for optimal margin classifiers. In *Proc. Fifth Annual Workshop on Computational Learning Theory*, pp. 144–152, 1992.
- [28] 砂川翔哉, 大倉史生, 榎原靖, 村松大吾, 八木康史. 乳牛の蹄病検出のための 3 次元歩行画像解析. 情報処理学会研究報告 コンピュータビジョンとイメージメディア, 第 2016-CVIM-202 巻, pp. 1–6, May 2016.