

Review and analysis of computational techniques and methods for body condition score estimation on cows

Juan Rodríguez Alvarez^{1,6}, Mauricio Arroqui^{2,4,6}, Pablo Mangudo^{2,4,6}, Juan Toloza^{2,4,6}, Daniel Jatip^{2,6}, Juan M. Rodríguez^{1,4,5}, Alejandro Zunino^{1,4,5}, Cristian Mateos^{1,4,5}, and Claudio Machado^{2,3,6}

¹ Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

² Agencia Nacional de Promoción Científica y Tecnológica (ANPCyT)

³ Facultad de Ciencias Veterinarias - UNICEN. Tandil, Buenos Aires, Argentina

⁴ Facultad de Ciencias Exactas - UNICEN. Tandil, Buenos Aires, Argentina

⁵ ISISTAN Research Institute - UNICEN. Tandil, Buenos Aires, Argentina

⁶ CIVETAN Research Institute - UNICEN. Tandil, Buenos Aires, Argentina

Abstract. BCS (Body Condition Score) is a method used to estimate body fat reserves and accumulated energy balance of cows. BCS heavily influences milk production, reproduction, and health of cows. Therefore, it is important to monitor BCS to achieve better animal response, but this is a time-consuming and subjective task performed oftentimes visually by expert scorers. These problems are the motivation behind several studies, which have tried to automate BCS of dairy cows by applying image analysis and machine learning techniques. This work analyzes these studies pointing out their main advantages and drawbacks, which allow us in turn to identify new research and development opportunities to improve overall automatic BCS estimation.

Keywords: Precision Livestock, Body Condition Score, Machine Learning, Deep Learning, Image Analysis, Convolutional Neural Networks.

Resumen BCS (del inglés "Body Condition Score") es un método utilizado para estimar las reservas de grasa corporal y el balance energético acumulado de las vacas. El BCS influye significativamente en la producción de leche, reproducción y salud de las vacas. Es por ello, que es importante monitorear este valor para lograr una mejor respuesta animal, pero resulta ser una tarea costosa en tiempo y subjetiva, realizada generalmente de manera visual por evaluadores expertos. Estos problemas conducen la motivación de varios estudios, que han tratado de automatizar el BCS de vacas lecheras aplicando técnicas de análisis de imágenes y aprendizaje automático. En este documento se analizan dichos estudios, señalando sus principales ventajas y desventajas, las que permiten además identificar nuevas oportunidades de investigación y desarrollo para mejorar el proceso general de automatización del BCS.

Keywords: Ganadería de Precisión, Condición Corporal, Aprendizaje Automático, Aprendizaje Profundo, Análisis de Imágenes, Redes Neuronales Convolucionales.

1. Introducción

El cambio de peso por sí sólo no es un buen indicador de las reservas energéticas de una vaca, ya que esta variable está afectada por diversos factores, como la etapa de lactancia, el tamaño de la estructura corporal o *frame* del animal, la etapa de gestación y la raza. En el caso de vacas lecheras, en la lactancia temprana (primeros 100 días del ciclo de lactancia) se produce una significativa movilización de tejidos que coincide con una modificación de la capacidad del contenido gastrointestinal, por lo que la disminución de peso vivo puede estar enmascarada por estos cambios. Las reservas de energía pueden variar hasta un 40 % en vacas de peso similar, lo que evidenció la necesidad de desarrollar un sistema para medir la condición corporal de las vacas [1].

La evaluación de la condición corporal (de ahora en más BCS, del inglés «Body Condition Score») es un indicador cuantitativo que permite estimar la grasa corporal almacenada como resultado del balance energético de las vacas. En general esta actividad se hace de manera visual, aunque puede incluir palpaciones sobre partes específicas del animal, como las zonas de las costillas, el lomo y la base de la cola. Una de las escalas de evaluación más utilizada es el sistema de 5-puntos, conocido también como US-BCS (del inglés United State BCS), desarrollado en 1982 [2]. Es una escala de 1 a 5 con incrementos de 0,25, donde 1 representa vacas emaciadas y 5 representa vacas obesas [3,4]. Un punto de condición corporal equivale a una diferencia de peso de 45 a 63 kg, según el nivel de condición [5]. Adicionalmente, Ferguson [3,4] mencionan que la condición corporal puede separarse en unidades de 0,25 puntos sólo entre los valores 2,5 y 4,0 inclusive, siendo inaplicable por debajo de 2,5 y por encima de 4,0 puntos. En general, se considera que vacas con BCS de 4,0 están muy gordas y vacas con BCS 2,5 están en mala condición corporal. Por consiguiente, tanto valores extremos de BCS, como la pérdida pronunciada de BCS se las asocia con mayores riesgos de salud, y posibilidades mayores de baja eficiencia reproductiva o productiva. Una vaca gorda es más susceptible a problemas metabólicos e infecciones, y más propensa a tener dificultades durante y después del parto. El sobre acondicionamiento o vacas gordas es mayormente una consecuencia de una inadecuada planificación nutricional. Por otro lado, las vacas muy flacas pueden disminuir la producción y los niveles de grasa de la leche y pueden además no entrar en celo o hacerlo de forma demorada [6,5].

El monitoreo regular del BCS es una herramienta muy útil para anticipar problemas de salud o nutricionales en el rodeo, minimizando las variaciones entre el valor máximo y mínimo esperado de BCS en las etapas críticas. El BCS al parto es un punto clave de gran influencia en el ciclo de lactancia [7,1]. En este sentido, en la lactancia temprana existen limitaciones de consumo de alimento, por lo que es muy dependiente de movilizar energía de la grasa corporal de reserva para sostener una gran producción de leche durante esta etapa. En general, se sugiere que el BCS no debe disminuir más de 1 punto desde el parto, aunque puede bajar inclusive 1,5 puntos sin afectar significativamente la performance de la vaca, siempre que su BCS no sea menor a 2,5. En la etapa final de la lactancia (300-305 días después del parto), la vaca ya no produce leche siendo el objetivo en este punto preparar los animales para el próximo ciclo de lactancia mediante el secado.

La estimación del BCS es una tarea que puede demandar mucho tiempo y requiere de personal calificado para su estimación precisa, y aún así puede haber discrepancias

de 0,25 o 0,50 puntos entre operadores. Debido a la importancia del BCS como variable de control del sistema ganadero, se encuentran en la bibliografía diferentes trabajos [8,9,10,11,12,13] orientados a desarrollar un método automático de medición del BCS que sustituya o complemente al método manual. Estos trabajos aplican técnicas de análisis de imágenes/video y aprendizaje automático (del inglés, *machine learning*) que permiten extraer características significativas para la estimación de BCS. En general, la bondad de estos métodos automáticos radica en acelerar el proceso de evaluación y lograr una mayor objetividad. En este trabajo por ende se realiza un análisis de dichos métodos, enfatizando comparativamente en sus ventajas y desventajas para su aplicación a un futuro desarrollo.

Este trabajo está estructurado de la siguiente manera. En la Sección 2 se realiza un relevamiento bibliográfico, describiendo diferentes trabajos que tienen por objetivo mejorar los procesos manuales de definición de BCS, contribuyendo al desarrollo de un método lo más automático y preciso posible. En la Sección 3 se realiza un análisis de los trabajos relevados, identificando diferencias, congruencias, grado de automatismo y calidad de los resultados de predicción. En la Sección 4 se presentan las conclusiones de este trabajo, identificando carencias de los actuales estudios e identificando posibles oportunidades y alternativas complementarias de investigación y desarrollo.

2. Antecedentes

En la literatura se encuentran diferentes estudios que se proponen estimar la condición corporal en vacas de forma automática o semi-automática. A continuación se describen algunos trabajos respetando un orden cronológico según su año de publicación, detallando los equipos utilizados para recolectar las imágenes, el conjunto de datos utilizados (raza de vacas y cantidad de imágenes) para el desarrollo y calibración del método de cuantificación/estimación de BCS, una breve descripción del método implementado y los resultados obtenidos en términos de la eficiencia predictiva del método particular.

2.1. Bewley et al. [14]

Este trabajo se basa en la hipótesis de que el BCS de una vaca se refleja en los ángulos que se forman alrededor de las puntas de cadera y la grupa, ángulos que pueden ser medidos utilizando imágenes digitales. Por ejemplo, las puntas de cadera son más prominentes y pronunciadas en una vaca delgada, como así también la depresión en la base de la cola. Para desarrollar y calibrar el método de predicción de BCS se recolectaron imágenes en blanco y negro de vacas de raza *Holstein-Friesian*, 834 en escala US-BCS y 767 en escala UK-BCS (del inglés United Kingdom BCS, escala de 0 a 5 a diferencia de la anterior), con una cámara digital ubicada a 60-70 cm sobre el lomo de las vacas. La cámara estaba posicionada en una estación de pesaje a la salida de la sala de ordeño, donde el animal se encerraba para realizar la captura. Las capturas se realizaban en el ordeño de la tarde (intermedio de 3 ordeños diarios), por limitaciones de luz tanto en el ordeño temprano de la mañana, y el segundo de la tarde/noche.

El método desarrollado para estimar el BCS incluía, la identificación manual de 23 puntos anatómicos sobre las imágenes, el cálculo de ángulos a partir de dichos puntos, y la confección final de dos modelos mixtos [15] para cada sistema/escala de BCS (US-BCS y UK-BCS) considerando los ángulos identificados como características. El primer modelo incluye sólo los mejores ángulos de la región de la punta de cadera (AHR, del inglés Angles in the Hook Region), mientras el segundo considera además los ángulos de la región de la grupa (ARR, del inglés Angles in the Rump Region) como características para estimar el BCS.

Aunque la región de la grupa representa el área de mayor deposición de grasa y es la más utilizada en los métodos visuales de evaluación del BCS, la depresión de la base de la cola (calculada como parte del modelo ARR) no mejora el modelado, por lo que los análisis se centran en el modelo AHR. De este modo, los resultados para el primer modelo mostraron que para el sistema US-BCS, el 100 % de los BCS estimados están dentro de 0,5 puntos del BCS real y 92,79 % dentro de 0,25 puntos. Para el sistema UK-BCS, el 99,87 % de los BCS estimados están dentro de 0,50 puntos del BCS real y 89,95 % dentro de 0,25 puntos.

2.2. Krukowski [16]

En este trabajo la autora propuso desarrollar y evaluar un algoritmo para el análisis de imágenes, que determine objetivamente el BCS en vacas lecheras usando una cámara con tecnología ToF (del inglés Time-of-Flight) que permita obtener información tridimensional de la forma del cuerpo de una vaca. Para ello utilizó 351 imágenes de 16 vacas de raza SRB (del inglés Swedish Red Breed) para el entrenamiento y 120 imágenes de 24 vacas para la validación, con rango de valor de BCS entre 2,75 y 4,25.

El método desarrollado para estimar el BCS incluye, segmentación de la imagen 3D para conservar sólo los puntos que pertenecen a la superficie de la vaca, identificación automática de puntos de referencia (puntas de cadera, espina), normalización de las superficies (traslaciones y rotaciones usando tales puntos de referencia) para hacerlas comparables, cálculo de características utilizando métricas de textura que analizan estadísticamente propiedades de la superficie (valores de profundidad, gradientes y vectores normales a la superficie), y confección final de dos modelos de estimación (uno lineal y otro con términos cuadráticos adicionales) utilizando las características que mejor se correlacionan con el BCS.

Los resultados obtenidos por la autora a la hora de evaluar ambos modelos sobre las imágenes de entrenamiento fueron aceptables, pero no así los resultados sobre las imágenes del conjunto de validación: sólo el 20 % de las estimaciones difieren por menos de 0,25 puntos con respecto al BCS manual, mientras que el 46 % se encuentra dentro 0,5 puntos de diferencia. La autora remarca que la diferencia en los resultados de los dos conjuntos puede estar relacionada a tres factores: i) la utilización de diferentes evaluadores, ii) la utilización de imágenes de menor calidad (ruido en la imagen), iii) diferencia en la forma que las imágenes fueron capturadas (ángulo de captura) para la validación.

2.3. Anglart [17]

En este estudio se utilizó una cámara 3D ToF para recolectar datos de referencia que permitan validar el cálculo automático del BCS. Este tipo de cámara presentó una limitación a la hora de estimar de manera apropiada la forma del área de la vaca en aquellas con pigmentación negra, por lo que se utilizaron vacas de raza SRB en los experimentos. Adicionalmente, de las imágenes recolectadas sobre las 70 vacas que participaron del estudio, el 30 % de las capturas tuvieron que descartarse debido a problemas con la posición de la vaca o a que había más de una vaca en la misma imagen.

El método desarrollado para estimar el BCS incluye segmentación de la imagen para extraer el cuerpo de la vaca de la imagen 3D, extracción de características, y confección del modelo de estimación utilizando redes neuronales [18,19]. Cabe señalar que la autora no da mayores detalles sobre estas actividades ya que tanto la implementación del modelo como las actividades previas fueron realizadas por ingenieros de la empresa DeLaval⁷.

La autora obtuvo los siguientes resultados analizando la correlación entre las estimaciones de BCS del método y las mediciones manuales: (i) $R=0,84$ ($p < 0,001$); (ii) 69 % de las estimaciones dentro del rango $\pm 0,25$, y 95 % dentro de $\pm 0,50$.

2.4. Azzaro et al. [13]

En este trabajo el principal objetivo fue desarrollar un método que permita estimar el BCS a partir de una descripción o representación particular simplificada de la forma del cuerpo de la vaca. Para llevar a cabo este trabajo, recolectaron 286 imágenes de 29 vacas de raza *Holstein-Friesian*, utilizando una cámara digital posicionada a 3m sobre el lomo de los animales. Dicha cámara estaba ubicada en la puerta de salida de la sala de ordeño, donde se retenían brevemente las vacas para obtener una captura relativamente estacionaria.

El método desarrollado para estimar el BCS incluye, identificación manual de 23 puntos anatómicos sobre la imagen, normalización de la forma de la vaca (definida a partir de los puntos anteriores), cálculo de una forma promedio de referencia entre todas las normalizadas, cálculo de descriptores formas utilizando KPCA (del inglés Kernel Principal Component Analysis) [20] lineal y polinomial para describir la figura de cada vaca según la diferencia con la forma promedio, y confección final de dos modelos de regresiones lineales, uno que utiliza como características los descriptores KPCA lineal y el otro los descriptores KPCA polinomial.

Para la validación de los resultados utilizaron el método LOOCV (del inglés Leave One Out Cross Validation), que permite calcular el error utilizando $n-1$ imágenes como datos de entrenamiento y la restante imagen como dato de validación. Este proceso se repite para todos los n posibles subconjuntos de $n-1$ imágenes, siendo el error final el promedio de los errores en cada proceso de validación (n errores). El modelo basado en KPCA lineal mostró un error=0,32, mientras que el modelo basado en KPCA polinomial obtuvo mejores resultados con error=0,31.

⁷ <https://www.delaval.com>

2.5. Halachmi et al. [21,12]

El objetivo de este trabajo fue desarrollar un aparato y método para el monitoreo automático y objetivo del BCS, evaluando la hipótesis de que la forma del cuerpo de una vaca gorda es más redondeada que la de una delgada, y por lo tanto, se ajusta mejor a la forma de una parábola. Es decir, los puntos extremos de las puntas de cadera y de la base de la cola de una vaca delgada divergen de la forma redondeada definida por la parábola. Para llevar a cabo el análisis los autores utilizaron 172 imágenes de vacas de raza *Holstein*, imágenes que son el resultado de un proceso de selección de cuadros de vídeos recopilados usando una cámara térmica, que supone ser una herramienta útil para extraer de manera simple la forma de la vaca del fondo de la imagen, resaltando la calidez de su cuerpo del frío de sus alrededores. Sin embargo, esta cámara tiene la desventaja de ser mucho más costosa que las cámaras digitales clásicas o con sensores de profundidad.

El método desarrollado para estimar el BCS incluye, selección automática del mejor cuadro de video de cada vaca, recorte del área de la imagen de interés y eliminación de objetos indeseados, extracción de características (contorno de la vaca y cálculo de una parábola ajustada a éste), cálculo del valor de angularidad como la diferencia entre las características previas, y confección final del modelo de estimación que adapta este valor de angularidad a la escala del BCS.

Los autores obtuvieron un valor de $R=0,94$ ($p < 0,01$) analizando la correlación entre el BCS estimado usando la cámara térmica y las evaluaciones manuales de los expertos.

2.6. Bercovich et al. [11]

En este trabajo propusieron desarrollar una herramienta automática de visualización computacional para estimar el BCS usando una cámara digital de bajo costo. El estudio se desarrolló sobre la base de trabajos previos, descritos en las Secciones 2.1, 2.4 y 2.5. Para ello recolectaron imágenes utilizando una cámara digital ubicada en la entrada a la sala de ordeño a 2,5m del suelo. Los datos se dividieron en dos conjuntos diferentes de capturas sobre vacas de raza *Holstein*: (1) conjunto de entrenamiento con 87 imágenes de vacas para el desarrollo del método; y (2) conjunto de validación con 64 imágenes de 41 vacas.

El método desarrollado para estimar el BCS incluye segmentación de la imagen, normalización del contorno de la base de la cola (representado por 1000 puntos interpolados en un plano x-y con valores escalados entre 1 y 0), extracción de características (distancias y ángulos entre puntos anatómicos identificados desde el contorno, y vector 1D representando la COW SIGNATURE del área de la base de la cola), y confección final de 3 modelos de estimación. Los modelos implementados abarcan: (a) regresión multivariable utilizando ángulos y distancias, (b) regresión PLS (del inglés Partial Least Squares) utilizando la COW SIGNATURE y (c) una regresión lineal utilizando descriptores de Fourier (FD por sus siglas en inglés) de la COW SIGNATURE. Se entiende por COW SIGNATURE a una representación derivada de la forma del cuerpo de la vaca, que en este caso se corresponde con un vector 1D de las

distancias Euclídeas entre cada punto del contorno normalizado y el centroide de dicho contorno (punto (0,5;0,5) del plano x-y mencionado anteriormente).

Los mejores resultados se obtuvieron con el modelo (c), con valor de $R^2=0,77$ entre el BCS manual y el estimado sobre el conjunto de entrenamiento. Es por ello que fue el único modelo aplicado sobre el conjunto de validación, obteniendo los siguientes resultados entre las calificaciones del modelo y las realizadas a mano: (i) $R^2 = 0,64$; (ii) error absoluto promedio 0,34; y (iii) 50 % de las evaluaciones dentro del rango de 0,25 puntos, y casi 100 % dentro de 0,75.

2.7. Salau et al. [22]

El objetivo del estudio fue analizar el poder descriptivo de características calculadas automáticamente a partir del análisis de imágenes para monitorear el BCS. Para ello utilizaron un método que incluye, selección y segmentación de imágenes, identificación de partes del cuerpo a partir del cálculo de la COW SIGNATURE de la vaca, y definición final de las características que impactan en el BCS como valores estadísticos calculados a partir de las partes del cuerpo reconocidas y los datos de profundidad originales. Para realizar este trabajo recolectaron 514 imágenes de 30 vacas de raza *Fleckvieh* utilizando una cámara 3D con tecnología ToF montada sobre la estación de pesaje a 2,55m de altura.

Las características identificadas automáticamente por el sistema se analizaron según su poder descriptivo, calculando la correlación de cada una de las ellas con el BCS definido por expertos. Los mejores resultados se obtuvieron a partir de las características extraídas de la región de la base de la cola ($0,3 < |R| < 0,5$, $p = 0,05$). En este sentido, se deduce que es posible utilizarlas sólo en combinación para estimar el BCS, ya que ninguna de éstas puede describirlo completamente por sí sola.

Los autores evaluaron además la precisión de un modelo lineal generalizado (con una función de enlace lineal por tramos) y el BCS definido por expertos utilizando 540 imágenes. Este modelo consideraba no sólo las características extraídas de las imágenes sino también la información de semana de lactancia de la vaca. El coeficiente de determinación entre este modelo y el BCS manual fue $R^2 = 0,7$.

2.8. Hansen et al. [10]

En este trabajo se presentan resultados preliminares de un sistema automático que permite medir el BCS a medida que una vaca camina debajo de una cámara 3D. El trabajo se basa en la idea de usar la curvatura de la superficie total del lomo de la vaca, dado que provee información relevante para estimar el BCS. Para llevar a cabo este trabajo se recolectaron imágenes utilizando una cámara con sensor de profundidad, ubicada a 1,5-2m sobre la vaca en un área con sombra. De un total de 200 vacas de raza *Holstein-Friesians*, el sistema logró capturar automáticamente sólo 115, de las cuales 95 de ellas se utilizaron para construir el método y evaluar su precisión, midiendo la concordancia entre la medición manual de BCS y el valor de angularidad calculado por el sistema.

El método desarrollado para estimar el BCS incluye segmentación de la imagen y normalización de la representación de la vaca, cálculo del valor de angularidad

utilizando un algoritmo conocido como «*rolling ball*», y confección final del modelo que adapta este valor de angularidad a la escala del BCS. El algoritmo de *rolling ball* define qué tan bien una superficie se ajusta a una pelota de un radio determinado.

Los valores de estimación obtenidos reflejaron la relación inversamente proporcional que existe entre el BCS y la angularidad de la figura de la vaca, pero el trabajo no presenta métricas numéricas de la precisión del sistema. En su lugar, los autores propusieron medir la repetibilidad de las evaluaciones del sistema determinando qué tan repetibles son las estimaciones para imágenes de una misma vaca. Para ello tomaron como datos imágenes de 15 vacas, con 5 capturas de cada una. Catorce de ellas fueron evaluadas dentro de 0,25 puntos de BCS, demostrando que el sistema presenta una buena repetibilidad.

2.9. Fischer et al. [9]

Este trabajo propone desarrollar y validar un método para evaluar el BCS usando capturas 3D de la superficie de la parte trasera del lomo de la vaca. Según observaciones realizadas sobre trabajos anteriores [21,14,13,11], dedujeron la importancia de enfocarse en el área del lomo que va desde las puntas de cadera a las puntas de nalga, utilizando toda la información disponible en la imagen de la forma de la vaca previamente procesada con técnicas de extracción de factores (PCA, PLSR y FD). Para llevar a cabo este trabajo, utilizaron una cámara con sensor de profundidad ubicada a 2m del suelo. El conjunto de entrenamiento estaba formado por 57 superficies 3D de 56 vacas de raza *Holstein*. Por su parte, los conjunto de validación contenían 25 vacas cada uno donde: (i) el conjunto denominado *stage* contenía vacas del conjunto de entrenamiento pero en diferentes etapas de lactancia, y (ii) el conjunto denominado *cows* contaba con vacas no usadas en el entrenamiento.

El método desarrollado para estimar el BCS incluía, identificación manual de 4 puntos anatómicos sobre las superficies capturadas, normalización de las superficies para hacerlas comparables (selección de misma cantidad de puntos 3D, resultando en el valor de 22500 píxeles), utilización de PCA para extraer un número reducido de factores representativos de las superficies, y confección final de un modelo de regresión lineal multivariable utilizando los componentes principales obtenidos como características.

El método generado mostró los siguientes resultados según la correlación entre el BCS estimado y el observado sobre cada conjunto de validación. Para el conjunto *stage*: (i) $R=0,89$ ($p < 10^{-16}$); (ii) $RMSE=0,31$ (del inglés Root Mean Square Error). Para el conjunto *cows*: (i) $R=0,96$ ($p < 10^{-16}$); (ii) $RMSE=0,32$.

2.10. Shelley [8]

Este trabajo desarrolló un sistema completamente autónomo que no sólo permite determinar el BCS de una vaca en un momento puntual, sino además detectar y monitorear el cambio gradual del BCS de un rodeo en un determinado intervalo de tiempo a medida que la condición corporal y el ciclo de lactancia de las vacas varían. Para el desarrollo y evaluación del método el autor usó un total de 18517 imágenes de 116 vacas de raza *Holstein*, que fueron recolectadas durante 7 meses utilizando una cámara con sensor de profundidad ubicada a 3,05m del suelo sobre la pasarela de las

vacas. Esta pasarela está posicionada a la salida de la sala de ordeño, en un ambiente cerrado y controlado para que la cámara no se vea afectada por elementos externos como la influencia del cambio de luz en las imágenes.

El método desarrollado para estimar el BCS incluye, selección automática de la mejor imagen de cada vaca, segmentación de la imagen para eliminar información del fondo, cálculo del valor de angularidad como la distancia entre la superficie angular del lomo de la vaca y parábolas ajustadas a lo largo del lomo (proceso similar al utilizado en [21,12] expandiendo el enfoque a uno tridimensional), y confección final del modelo que adapta este valor de angularidad a la escala del BCS. Siguiendo la misma lógica que en el trabajo de Halachmi [21,12], si una vaca es más gorda, la forma de su cuerpo será más redondeada y por lo tanto las parábolas se ajustarán mejor a dicha forma. Por el contrario, si una vaca es delgada, la forma de su cuerpo será menos redondeada y por ende las distancias con las parábolas mayor.

El autor obtuvo los siguientes resultados considerando la correlación entre el BCS estimado y el determinado por los expertos: (i) $R^2 = 0,5421$, con una correlación lineal $y = 0,519x + 1,344$; (ii) 93,91 % de las estimaciones dentro del rango 0,5 y el 71,35 % dentro de 0,25 puntos de BCS.

2.11. Spoliansky et al. [23]

El objetivo de este trabajo fue desarrollar un sistema de visión computacional 3D de bajo costo, que permita capturar imágenes de manera automática, y no requiera intervención humana durante el proceso de evaluación de la condición corporal. Para realizar este trabajo los autores utilizaron 14474 imágenes, obtenidas a partir de 389 videos de 101 vacas. Las imágenes de video fueron recolectadas automáticamente a medida que las vacas caminaban debajo de una cámara equipada con sensor de profundidad, ubicada a la salida de la sala de ordeño a 2,5 m del suelo. Los autores utilizaron un detector de movimiento infrarrojo pasivo como disparador de la grabaciones, ubicado 0,3 m antes de la cámara. Cada vez que la cámara se activa, se registra un video de 4 segundos que contiene entre 100-120 cuadros, del cual se seleccionan automáticamente sólo aquellos que contengan la parte final del lomo de una vaca.

El método desarrollado para estimar el BCS comprende segmentación del fondo de la imagen, selección de imágenes relevantes (aquellas que contengan una vaca), normalización (rotación de la imagen, y escalado de valores de píxeles entre 0 y 1), extracción de características (12 calculadas y generadas a partir de diversas operaciones sobre los valores de profundidad de los píxeles) y confección final de un modelo de regresión polinomial con términos cuadráticos que utiliza las características derivadas de la imagen y 2 valores externos adicionales obtenidos de los registros del establecimiento ganadero (peso y edad)

Los autores obtuvieron los siguientes resultados según la correlación entre el BCS estimado y el determinado por los expertos: (i) $R^2 = 0,75$; (ii) $MAE = 0,26$; (iii) 74 % de las estimaciones dentro del rango 0,25, 91 % dentro de 0,50 y 100 % dentro de 1 punto de BCS.

Adicionalmente, cabe señalar que la técnica de selección automática de imágenes implementada produjo un 0 % de falsos positivos (100 % de las imágenes seleccionadas

contenían correctamente el lomo de la vaca, mientras que el 100 % de las rechazadas no lo hacían) y un error del 7,82 % en no seleccionar videos que sí incluían la parte final del lomo de la vaca.

3. Análisis comparativo de los trabajos relevados

Con el fin de organizar los diferentes esfuerzos en función de sus características, y así identificar puntos fuertes y puntos débiles, en los Cuadros 1, 2 y 3 se muestra una comparativa entre los diferentes trabajos descritos anteriormente, considerando los siguientes factores:

- **Cámara:** refiere al tipo de cámara que se utiliza para capturar las imágenes. Entre las identificadas en la literatura se encuentran: térmicas, digitales 2D, y 3D con tecnología ToF o *Light Coding* (codificación de proyección de patrones de luz).
- **Raza:** indica la raza de vaca utilizada en los experimentos, entre las que es posible mencionar: Holstein, SRB y Fleckvieh.
- **Conjunto de datos (imágenes):** es la cantidad de imágenes de vacas contenidas en el conjunto de datos y que fueron utilizadas en el análisis.
- **Automatización:** representa el nivel de automatización del método de estimación desarrollado. Los niveles diferenciados son tres: a) bajo, donde se requiere identificar manualmente puntos de referencia en la imagen, b) medio, donde se seleccionan manualmente las imágenes a utilizar, c) alto donde el proceso es completamente automático.
- **Tiempo real:** indica si el valor estimado de BCS está disponible en el instante posterior a la captura, o si el tiempo necesario para las tareas de procesamiento e interpretación de la imagen difieren la obtención este valor.
- **Segmentación:** hace referencia a si la imagen se segmenta separando la parte que corresponde a la vaca de la imagen de fondo.
- **Normalización:** señala si se realiza alguna normalización sobre la representación de la vaca en la imagen para hacerla independiente de sus dimensiones.
- **Características:** enumera las principales características de la vaca derivadas del análisis de imágenes o fuentes externas, que se utilizan como entradas en el modelo de predicción.
- **Modelo:** el tipo de modelo utilizado para estimar el BCS a partir de las características identificadas.
- **Resultados:** los principales resultados obtenidos, que a grandes rasgos representan el porcentaje de error, la correlación entre el BCS real y el estimado, y la precisión de los modelos dentro de los rangos de error humano.

En líneas generales, los métodos encontrados para estimar el BCS presentan dos etapas. En una primera etapa se involucran técnicas de análisis de imágenes para extraer características relevantes que contribuyan a diferenciar los niveles de reservas de grasas de las vacas. En una segunda etapa, las características recolectadas se utilizan para implementar un modelo de estimación de BCS. Las características que se seleccionan para la construcción de los modelos abarcan: ángulos, distancias y áreas entre puntos anatómicos; valores de intensidad/profundidad de los píxeles; parámetros derivados

Trabajos secciones	Cámara	Raza	Conjunto de datos (imágenes)	Automatización	Tiempo real	Segmentación	Normalización	Características	Modelo	Resultados
Bewley et al. [14]	Digital, 2D	Holstein-Fresian	834 (US-BCS), 767 (UK-BCS)	Baja	NO	NO	NO	Ángulos definidos por los puntos anatómicos	2 modelos mixtos, usando en uno ángulos adicionales.	92,79 % dentro de 0,25, 100 % dentro de 0,5
Krukowski [16]	TOF, 3D	SRB	351 entrenamiento, 120 test	Media	NO	SI	SI	Identificación de partes anatómicas de la vaca y cálculo de valores derivados	RL: Regresión lineal. RP: Regresión Polinomial (términos cuadráticos)	Conj. Test (RP): 20 % dentro de 0,25, 46 % dentro de 0,5
Anglart [17]	ToF, 3D	SRB	1329 (10 % entrenamiento, 90 % test)	Media	S/D	S/D	S/D	S/D: Información 3D de la zona apófisis transversa	S/D: Red Neuronal	$R = 0,84$. 69 % dentro de 0,25, 95 % dentro de 0,50
Azzaro et al. [13]	Digital, 2D	Holstein-Fresian	286	Baja	NO	NO	SI	Definición de formas. KPCA para obtener descriptores de formas respecto de una promedio.	Regresión por Componentes Principales	$Error_{LOOCV} = 0,31$

S/D: Sin Detalles

Cuadro 1. Comparación entre los trabajos relevados.

Trabajos secciones	Cámara	Raza	Conjunto de datos (imágenes)	Automatización	Tiempo real	Segmentación	Normalización	Características	Modelo	Resultados
Halachmi et al. [12]	Térmica	Holstein	172	Alta	SI	SI	NO	Contorno vaca, parábola ajustada	Función de desviación (MAE) entre parábola ajustada y contorno de la vaca (angularidad)	$R = 0,94$
Berovich et al. [11]	Digital 2D	Holstein	87 entrenamiento, 64 test	Media	NO	SI	SI	Distancias y ángulos entre puntos anatómicos, y COW SIGNATURE.	3 regresiones lineales. Mejor modelo usa descriptores de Fourier de la COW SIGNATURES (DF-CW)	Conj. Test (DF-CW): $R^2 = 0,64$. 43% dentro de 0,25, 72% dentro de 0,50
Salau et al. [22]	ToF 3D	Fleckvieh	540 (para MLG), 514 (para características individuales)	Alta	NO	SI	NO	Áreas y distancias entre partes del cuerpo de la vaca identificadas a partir de la COW SIGNATURE, funciones polinomiales derivadas	CI: correlación de características individuales con el BCS manual. MLG: Modelo lineal generalizado usando todas las características	$R^2_{MLG} = 0,7$
Hansen et al. [10]	Light Coding, 3D	Holstein-Friesian	95	Alta	SI	SI	SI	Superficie tridimensional de la vaca, y estera ajustada	Rolling Ball (angularidad en 3D)	S/D. Buena repetitividad evaluando la misma vaca (14/15). Relación inversamente proporcional e/ angularidad y BCS

S/D: Sin Detalles

Cuadro 2. Comparación entre los trabajos relevantes.

Trabajos secciones	Cámara	Raza	Conjunto de datos (imágenes)	Automatización	Tiempo real	Segmentación	Normalización	Características	Modelo	Resultados
Fischer et al. [9]	<i>Light Coding</i> , 3D	Holstein	57 entrenamiento, 25 test cows, 25 test stage	Baja	NO	NO	SI	PCA sobre los valores x,y,z de los píxeles normalizados	Regresión por Componentes Principales	Conjunto <i>stage</i> (vacas de otra etapa de lactancia): $R = 0,89$ y $RMSE = 0,31$. Conjunto <i>cows</i> (test): $R = 0,96$ y $RMSE = 0,32$
Shelley [8]	<i>Light Coding</i> , 3D	Holstein	18517	Alta	NO	SI	NO	Contornos transversales de la vaca y sus correspondientes curvas ajustadas Cálculos derivados sobre valores de profundidad (por zonas y generales a la imagen), distancia del centro al contorno de la vaca, peso, edad	Distancia/diferencia (MAEs) de todos los contornos y las curvas ajustadas (angularidad)	71,35 % dentro 0,25, 93,91 % dentro de 0,5
Spoliansky et al. [23]	<i>Light Coding</i> , 3D	Holstein	11824 entrenamiento, 2650 test	Alta	NO	SI	SI		Regresión polinomial usando términos cuadráticos	$R^2 = 0,75$, $MAE = 0,26$, 74 % dentro 0,25, 91 % dentro 0,5

S/D: Sin Detalles

Cuadro 3. Comparación entre los trabajos relevados.

de los anteriores; contorno de la vaca o una representación de ella. En relación a los modelos utilizados, se destacan mayormente dos tipos: i) regresiones, que usan una combinación de las características identificadas en la imagen para predecir el BCS; ii) algoritmos que miden el grado de angularidad de la figura de la vaca usando la hipótesis de que a mayor BCS es más redondeada, y por lo tanto menos angular.

Respecto a las cámaras utilizadas, se observa que en los trabajos más actuales hay una tendencia a adoptar cámaras 3D, que brindan información adicional de profundidad de la superficie del lomo de la vaca. El trabajo de Halachmi (Sección 2.5) es el único que utiliza una cámara térmica. Sin embargo, este tipo de cámaras no son tenidas en cuenta en los restantes trabajos por su elevado costo. Por ejemplo, la cámara térmica utilizada en el trabajo de Halachmi ronda entre los 5000 y 6000 dólares, mientras que una cámara 3D ToF como la Kinect V2 ronda los 100 dólares.

En relación a la cantidad de imágenes utilizadas en los experimentos, sólo los trabajos de Shelley y Spoliansky (Secciones 2.10 y 2.11 respectivamente) usan un conjunto de datos con tamaño importante para el desarrollo del modelo. El resto de los trabajos no alcanzan el piso de 1000 imágenes recolectadas, y algunos inclusive están en el orden de 100 imágenes como es el caso de los trabajos de Bercovich et al., Hansen et al. y Fischer et al. (Secciones 2.6, 2.8 y 2.9 respectivamente). Esto puede afectar la precisión de los modelos ante la presencia de nuevas imágenes, no reflejando el potencial real de estimación.

En los trabajos es posible identificar 3 niveles de automatización para estimar el BCS. En el nivel «bajo» se encuentran los trabajos de Bewley, Azzaro y Fischer (Secciones 2.1, 2.4 y 2.9 respectivamente) en los cuales es necesario identificar manualmente puntos de referencia en la imagen que faciliten la extracción de las características que van a ser utilizadas para implementar los modelos de estimación. En el nivel «medio» se encuentran los trabajos de Krukowski, Anglart y Bercovich (Secciones 2.2, 2.3 y 2.6) donde se seleccionan manualmente las imágenes recolectadas a utilizar y se descartan las defectuosas, pero el resto del proceso es automático. Finalmente en el nivel «alto» se encuentran los trabajos de Salau, Hansen, Halachmi, Shelley y Spoliansky (Secciones 2.7, 2.8, 2.5, 2.10, 2.11 respectivamente) donde se logra un proceso completamente automatizado. De estos últimos, sólo Halachmi y Hansen logran realizar estimaciones en tiempo real, debido al tiempo que demandan las técnicas de preprocesamiento de imágenes aplicadas en los otros trabajos.

Por último, en cuanto a las tareas de preprocesamiento, la mayoría de los trabajos utilizan técnicas de segmentación para separar la vaca de la imagen eliminando información de fondo, mientras en los trabajos de Bewley, Azzaro y Fischer (Secciones 2.1, 2.4 y 2.9 respectivamente) esta separación se logra a partir de la identificación de puntos anatómicos que delimitan de cierta forma la porción de la imagen que corresponde a la vaca. Los trabajos de Krukowski, Bercovich, Azzaro, Hansen, Fischer y Spoliansky (Secciones 2.2, 2.6, 2.4, 2.8, 2.9 y 2.11 respectivamente) requieren utilizar técnicas de normalización que les permita estandarizar la representación de la vaca en la imagen para que sea independiente de la altura o tamaño del animal, o de la ubicación al momento de la captura. En otros trabajos se usan características para el modelado del BCS que tienen por sí mismas una naturaleza adimensional por lo que no requieren tareas de estandarización, como los

ángulos entre puntos anatómicos de referencia. De la misma manera, los trabajos de Halachmi y Shelley (Secciones 2.5 y 2.10, respectivamente) que utilizan el contorno de la vaca para medir angularidad, en lugar de normalizar dichos contornos ajustan para cada caso la superficie de comparación (parábolas o esferas ajustadas).

4. Discusión

Existen diferentes trabajos que intentan resolver el problema de estimar el valor BCS de manera automática, con una precisión comparable a la de los expertos que realizan evaluaciones manuales en el lugar. En este sentido, el indicador más utilizado por los autores para validar los resultados obtenidos es la precisión de dicha estimación entre los intervalos susceptibles a error humano o entre diferentes evaluadores (0,25 y 0,50), aunque no hay una homogeneidad entre las métricas calculadas en todos los trabajos. Es por ello que resulta interesante desarrollar un diseño experimental más riguroso, que incluya un análisis de métricas más exhaustivo y permita realizar comparaciones entre los resultados de los diferentes trabajos. En este sentido es importante remarcar la necesidad de contar con un buen conjunto de datos entrenamientos para el aprendizaje del modelo y otro buen conjunto de validación para verificar la verdadera precisión del modelo, previendo problemas como el *overffiting*, que conduce a modelos poco generales y muy ajustados a los datos de entrenamiento.

En la literatura hay trabajos que logran obtener buenos resultados dentro del rango de error esperado, como el caso del trabajo de Shelley (Sección 2.10), pero sin embargo presenta la desventaja que las estimaciones de BCS no son en tiempo real, condicionado particularmente por las técnicas de preprocesamiento de imágenes que intervienen el proceso de evaluación. Aunque existen trabajos que sí estiman el BCS en tiempo real, como el de Hansen y el de Halachmi (Secciones 2.8 y 2.5 respectivamente), en el primero no se realiza un análisis detallado sobre los resultados obtenidos y utiliza un número reducido de imágenes, mientras el segundo usa cámaras térmicas que como ya se mencionó resultan ser costosas en relación a otro tipo de cámaras. La estimación del BCS en tiempo real en un contexto de producción de leche no representa un problema ya que en general se interactúa con el animal al menos 2 veces por día. Sin embargo, en actividades orientadas a la producción de carne, como la cría vacuna en particular, la interacción con el animal se realiza con una frecuencia sólo estacional, por lo que este punto toma mayor importancia ya que las medidas de contingencia deben aplicarse de forma inmediata (ej. separar lotes) para evitar movimientos innecesarios de la hacienda. Argentina puntualmente cuenta con un stock de 51,4 millones de bovinos para producción de carne, que están orientados mayormente a actividades de cría, según valores del coeficiente de orientación productiva ($\cong 0,3$) del SENASA que calcula la relación entre novillos, novillitos y toritos sobre el total de vacas [24]. La aplicación de un sistema automático tanto para leche como para carne requerirá de un conjunto de datos de entrenamiento y validación diferenciado, ya que implica vacas de diferentes razas y es necesario garantizar que el valor de BCS estimado tenga en cuenta el *frame* o estructura corporal de la raza correspondiente. Estas oportunidades ampliadas de aplicación, indican la necesidad de desarrollar un sistema que se extienda más allá de la producción lechera.

En este sentido, el uso de Aprendizaje Profundo (del inglés, Deep Learning) y en particular CNN [25,26] (del inglés Convolutional Neural Networks) es una área no explorada aún en la literatura. Las CNN han mostrado un gran desempeño en el problema de clasificación de imágenes [27,28,29], como es el caso de la estimación del BCS a partir de imágenes digitales o 3D, donde la tarea es clasificar una imagen según un conjunto de categorías dadas, basado en el contenido visual de la imagen. A diferencia de los métodos analizados en este trabajo donde el BCS estimado se representa como un valor continuo, en la clasificación de imágenes se manifiesta el concepto de categorías, que en el caso del BCS van a estar representadas por cada uno de los posibles valores discretos en el rango del BCS (valores de 1 a 5, cada 0,25 puntos). Similar a las etapas identificadas en los trabajos recopilados, el método convencional de clasificación de imágenes consiste de dos módulos separados: (i) módulo de extracción de características y (ii) módulo de clasificación. Las CNN tienen la ventaja de integrar ambos módulos durante la etapa de entrenamiento del modelo, presentando una arquitectura de red neuronal particular donde las primeras capas se encargan de extraer características y las últimas se encargan de combinarlas para completar la clasificación de la imagen. Bajo este esquema, la red aprende a extraer patrones o características de la imagen basándose en la precisión alcanzada por la red, y no de manera previa e independiente al resultado de la clasificación. Si bien este tipo de técnicas resulta computacionalmente compleja en términos de recursos durante la etapa de entrenamiento, a la hora de utilizar el modelo resultante en la práctica para estimar el BCS correspondiente de una imagen todo se resuelve a una combinación de operaciones aritméticas sobre los valores de intensidad de los píxeles que la componen.

5. Agradecimientos

Este proyecto de investigación se realiza con una beca doctoral otorgada por el CONICET al primer autor y dentro del marco del proyecto D-TEC 05/2013: “Ampliación de la capacidad tecnológica interdisciplinaria para una mayor y más efectiva adopción de TICs en producción animal”, dirigido por el Dr. Claudio Machado y co-dirigido por el Dr. Alejandro Zunino, donde se planea desarrollar un prototipo funcional del método basado en CNN descrito anteriormente.

Referencias

1. Roche, J.R., Friggens, N.C., Kay, J.K., Fisher, M.W., Stafford, K.J., Berry, D.P.: Invited review: Body condition score and its association with dairy cow productivity, health, and welfare. *Journal of dairy science* 92(12), 5769–5801 (2009)
2. Wildman, E., Jones, G., Wagner, P., Boman, R., Troutt, H., Lesch, T.: A dairy cow body condition scoring system and its relationship to selected production characteristics. *Journal of Dairy Science* 65(3), 495–501 (1982)
3. Ferguson, J., Azzaro, G., Licitra, G.: Body condition assessment using digital images. *Journal of dairy science* 89(10), 3833–3841 (2006)
4. Ferguson, J.D., Galligan, D.T., Thomsen, N.: Principal descriptors of body condition score in holstein cows. *Journal of Dairy Science* 77(9), 2695–2703 (1994)

5. Kellogg, W.: Body Condition Scoring With Dairy Cattle. University of Arkansas, Division of Agriculture, <https://www.uaex.edu/publications/pdf/FSA-4008.pdf>
6. Heinrichs, A., Jones, C., Ishler, V.: Body condition scoring as a tool for dairy herd management. Penn State College of Agricultural Sciences
7. Markusfeld, O., Galon, N., Ezra, E.: Body condition score, health, yield and fertility in dairy cows. *The Veterinary Record* 141(3), 67–72 (1997)
8. Shelley, A.N.: Incorporating machine vision in precision dairy farming technologies. Ph.D. thesis, University of Kentucky (2016)
9. Fischer, A., Luginbühl, T., Delattre, L., Delouard, J., Faverdin, P.: Rear shape in 3 dimensions summarized by principal component analysis is a good predictor of body condition score in holstein dairy cows. *Journal of dairy science* 98(7), 4465–4476 (2015)
10. Hansen, M., Smith, M., Smith, L., Hales, I., Forbes, D.: Non-intrusive automated measurement of dairy cow body condition using 3d video. In: *Proceedings of the Machine Vision of Animals and their Behaviour (MVAB)*. pp. 1.1–1.8. BMVA Press (September 2015), <https://dx.doi.org/10.5244/C.29.MVAB.1>
11. Bercovich, A., Edan, Y., Alchanatis, V., Moallem, U., Parmet, Y., Honig, H., Maltz, E., Antler, A., Halachmi, I.: Development of an automatic cow body condition scoring using body shape signature and fourier descriptors. *Journal of dairy science* 96(12), 8047–8059 (2013)
12. Halachmi, I., Klopčič, M., Polak, P., Roberts, D., Bewley, J.: Automatic assessment of dairy cattle body condition score using thermal imaging. *Computers and electronics in agriculture* 99, 35–40 (2013)
13. Azzaro, G., Caccamo, M., Ferguson, J., Battiato, S., Farinella, G., Guarnera, G., Puglisi, G., Petriglieri, R., Licitra, G.: Objective estimation of body condition score by modeling cow body shape from digital images. *Journal of Dairy Science* 94(4), 2126–2137 (2011), <http://www.sciencedirect.com/science/article/pii/S0022030211001846>
14. Bewley, J., Peacock, A., Lewis, O., Boyce, R., Roberts, D., Coffey, M., Kenyon, S., Schutz, M.: Potential for estimation of body condition scores in dairy cattle from digital images. *Journal of dairy science* 91(9), 3439–3453 (2008)
15. Wang, Z., Goonewardene, L.: The use of mixed models in the analysis of animal experiments with repeated measures data. *Canadian Journal of Animal Science* (2004)
16. Krukowski, M.: Automatic determination of body condition score of dairy cows from 3D images. Master's thesis, Royal Institute of Technology, School of Computer Science and Communication (2009)
17. Anglart, D.: Automatic estimation of body weight and body condition score in dairy cows using 3D imaging technique. Master's thesis, Faculty of Veterinary Medicine and Animal Science, Swedish University of Agricultural Sciences (2010)
18. Bishop, C.M.: *Neural networks for pattern recognition*. Oxford university press (1995)
19. Demuth, H.B., Beale, M.H., De Jess, O., Hagan, M.T.: *Neural Network Design*. Martin Hagan, USA, 2nd edn. (2014)
20. Schölkopf, B., Smola, A., Müller, K.R.: Kernel principal component analysis. In: *International Conference on Artificial Neural Networks*. pp. 583–588. Springer (1997)
21. Halachmi, I., Polak, P., Roberts, D., Klopčič, M.: Cow body shape and automation of condition scoring. *Journal of dairy science* 91(11), 4444–4451 (2008)
22. Salau, J., Haas, J., Junge, W., Bauer, U., Harms, J., Bieletzki, S.: Feasibility of automated body trait determination using the sr4k time-of-flight camera in cow barns. *Springer Plus* 3, 225 (2014)
23. Spoliansky, R., Edan, Y., Parmet, Y., Halachmi, I.: Development of automatic body condition scoring using a low-cost 3-dimensional kinect camera. *Journal of Dairy Science* 99(9), 7714–7725 (2016)

24. Calvi, M., Cendon, M., Frade, M., Iturrioz, G., Nigro, H., Pavan, E., Pellerano, L., Pordomingo, A., Aranzadi, B., Arzubi, A., Dobaño, N., Marchetti, S., Moares, J., Otaño, C., Papotto, D., Piperata, M., Vidal, R., Rodríguez Vázquez, G.: Caracterización de la producción bovina. Sistema de monitoreo del sector de la carne bovina. Serie 1. Tech. rep., Ministerio de Agroindustria. Presidencia de la Nación, Subsecretaría de Ganadería. (2015)
25. Bengio, Y., Goodfellow, I.J., Courville, A.: Deep learning. *Nature* 521, 436–444 (2015)
26. Deng, L., Yu, D., et al.: Deep learning: methods and applications. *Foundations and Trends® in Signal Processing* 7(3–4), 197–387 (2014)
27. Hijazi, S., Kumar, R., Rowen, C.: Using convolutional neural networks for image recognition (2015)
28. Krizhevsky, A., Sutskever, I., Hinton, G.E.: Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*. pp. 1097–1105 (2012)
29. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., Rabinovich, A.: Going deeper with convolutions. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. pp. 1–9 (2015)