

Алтухов А. В. (1,2), Андрус Р. (3), Бурканов В. Н. (1,2,4), Усатов И. А. (1), Желат Т. С. (4)

**Использование машинного обучения для автоматизации поиска меченых сивучей (*Eumetopias jubatus*, Schreber) на панорамных фотографиях высокого разрешения**

(1) Камчатский филиал ФГБУН Тихоокеанского института географии ДВО РАН, Петропавловск-Камчатский, Россия

(2) Консалтинговая компания по дикой природе Северной Пацифики, Аляска, США

(3) Морская экология и телеметрические исследования, Вашингтон, США

(4) Лаборатория морских млекопитающих Аляскинского рыбохозяйственного центра Национальной службы морского рыболовства, НОАА, Сиэтл, США

Актуальные сведения о демографии сивуча имеют решающее значение для принятия обоснованных решений для сохранения вида. Визуальные наблюдения на лежбищах в прошлом были стандартом для получения информации о демографических показателях. Но с 2012 года мы начали использовать на лежбищах автономные фоторегистраторы. Всего за период 2012-2019 гг. получили более 16 миллионов изображений с различных лежбищ сивуча в России и США. Просмотр такого количества фотографий вручную является трудоемкой задачей. Поэтому мы разработали компьютерный алгоритм поиска меченых животных с использованием R, KERAS и TensorFlow. Нейронная сеть U-Net применялась для обнаружения потенциально меченых особей на изображении, а сеть VGG16 использовалась для выборки фактически меченных из первой выборки. К примеру, извлечение данных из 30 269 изображений заняло около 96 часов машинного времени, в то время как наблюдателям на эту работу потребовалось 960 часов. Нейронные сети редко пропускали метки (1-23% встреч, от всех меток обнаруженных вручную), но обнаруживала на 25-40% больше меток, чем наблюдатели. На первом этапе пропуск меток нейронными сетями в среднем составил 7% (SD = 13%). Однако ни одно меченное животное не было пропущено поскольку каждая камера снимает несколько десятков изображений в день, и пропущенное на одной фотографии меченое животное обнаруживается на других фотографиях. Основные пропуски меток были на изображениях мокрых сивучей и снятых при плохом освещении ранним утром или поздним вечером. Мы добавили к обучающим данным 1687 аннотированных изображений мокрых животных и повторно обучили модель. На втором этапе пропуск меток снизился до 1-5%. Автоматизированный подход позволил значительно сократить время извлечения нужной информации с фотографий, унифицировать усилия и алгоритм поиска меток на всех лежбищах, что позитивно отразилось на качестве первичной информации необходимой для расчета и сравнения демографических индексов популяций сивуча в разных географических районах.

Altukhov A. V. (1,2), Andrews R. (3), Burkanov V. N. (1,2,4), Usatov I. A. (1,2), Gelatt T. S. (4)

**Machine learning approach to automate identification of branded Steller sea lions (*Eumetopias jubatus* Schreber) in high-resolution images**

(1) Kamchatka Branch of the Pacific Geographical Institute, Far-Eastern Branch RAS, Petropavlovsk-Kamchatsky, Russia

(2) North Pacific Wildlife Consulting, Alaska, USA

(3) Marine Ecology and Telemetry Research, Seabeck, USA

(4) Marine Mammal Laboratory, Alaska Fisheries Science Center, National Marine Fisheries Service, NOAA, Seattle, WA, USA

Updated demographic data for endangered Steller sea lions (SSL) are critical for informed decision-making. Human observations of branded SSL has been the standard for generating vital rates information. Since 2012 customized autonomous time-lapse-cameras (TLC) have supplemented this work. We have collected over 16 million images from SSL rookeries in Russia and the Western Aleutian Islands, leading to the time-consuming problem of reviewing all the images. To remedy this problem, we developed machine learning algorithms using R, KERAS and TensorFlow to automate and accelerate marked SSL ID extraction. A U-Net convolutional neural network was used to detect branded SSLs among unmarked SSL

on each image, while the VGG16 neural network was used to classify branded animals. In our pilot study the data extraction from 30,269 images took about 96 hours of machine time, while an observer needed 960 hours to manually review the same number of images. The Deep learning algorithms rarely missed animals (missing 1-23% of animal encounters seen by an observer) and they discovered more IDs than observers (25-40% more ID identifications). An average false negative rate introduced by classification CNN was 7% (SD=13%). Despite this false negative rate, no branded SSLs that were present throughout a day were missed that day because our dataset consists of several dozen images per day for each TLC. Branded SSL that were wet in the early mornings and late evenings drove the false negative rate, likely due to an absence of similar images in our initial training set. We added 1687 annotated images to the training data and re-trained the model to detect missed brands. In subsequent evaluation, the false negative rate decreased to 1-5%. Using this automated approach, we significantly reduced the time needed to extract ID information, improved performance, and unified analysis across all sites.