

ABSTRACT

We live in a world that is in a constant state of change. This applies not at least to predictive models in machine learning or artificial intelligence. The change of our environment is described by concept drifts.

For detection of concept drifts, many methods need true labels. However, computing the deviation of the predictions from the true values can take some time, since labels in a stream are not always available immediately and sometimes not completely available. To avoid making predictions with a model that is outdated for the current time, unsupervised methods are often used. However, when these approaches rely only on monitoring the distribution of input features, certain types of concept drifts cannot be detected.

Therefore, in this method, the predictive uncertainty of the model is measured by an ensemble and used as an indicator of a concept drift. After a detection, an adjustment takes place by retraining the whole ensemble or only parts of the ensemble on data of the last context. Comparisons are made between the detection and adaptation of an ensemble of neural networks to a neural network using Monte Carlo Dropouts on a range of synthetic and real-world data sets addressing both regression and classification problems. It is shown that, in contrast to Monte Carlo Dropouts in a neural network, neural network ensembles not only output the more conservative estimate of predictive uncertainty as evidenced in numerous studies, but are also better suited in dealing with data in which concept drifts are present.

Keywords— Concept Drift, Detection, Handling, Model Uncertainty, Ensembles, Monte Carlo Dropouts, Streaming

ZUSAMMENFASSUNG

Wir leben in einer Welt, die sich in einem ständigen Wandel befindet. Dies betrifft nicht zuletzt prädiktive Modelle aus dem Machine Learning bzw. der Künstlichen Intelligenz. Die Veränderung unserer Umwelt wird durch Concept Drifts beschrieben.

Für die Detektion von Concept Drifts braucht es in vielen Methoden die wahren Labels. Die Abweichung der Vorhersagen zu den wahren Werten zu berechnen kann aber einige Zeit dauern, da Labels in einem Stream nicht immer sofort und erst recht nicht vollständig vorliegen. Um nicht mit einem für den aktuellen Zeitpunkt veralteten Modell Vorhersagen zu treffen, werden häufig unüberwachte Methoden verwendet. Wenn diese Ansätze nur auf der Überwachung der Verteilung der Input Features beruhen, können bestimmte Arten von Concept Drifts jedoch nicht detektiert werden.

Daher wird in dieser Methode die prädiktive Unsicherheit des Modells durch ein Ensemble gemessen und als Indikator für einen Concept Drift verwendet. Nach einer Detektion findet gleichzeitig noch eine Anpassung statt, indem das gesamte Ensemble oder nur Teile des Ensembles neu an die zuletzt aktuelle Situation angepasst werden. Es wurden Vergleiche zwischen der Detektion und Anpassung von einem Ensemble aus Neuronalen Netzen zu einem Neuronalen Netz unter Verwendung von Monte-Carlo Dropouts gezogen. Diese wurden auf einer Reihe von synthetischen und Real-World Datensätzen durchgeführt, die sowohl Regressions- als auch Klassifikationsprobleme adressieren. Es wurde gezeigt, dass Ensembles aus Neuronalen Netzen im Gegensatz zu Monte-Carlo Dropouts in einem Neuronalen Netz nicht nur wie in zahlreichen Studien belegt die konservativere Schätzung der prädiktiven Unsicherheit ausgeben, sondern auch im Umgang mit Daten besser geeignet sind, in denen Concept Drifts vorliegen.

Schlagerworte— Concept Drift, Detektion, Handling, Model Uncertainty, Ensembles, Monte-Carlo Dropouts, Streaming