ПРОБЛЕМА МНОГОКЛАССОВОЙ КЛАССИФИКАЦИИ В МАШИННОМ ОБУЧЕНИИ

THE PROBLEM OF MULTICLASS CLASSIFICATION IN MACHINE LEARNING

Орақов Орынбасар Талғатұлы, студент, Казахский Национальный Университет имени Аль-Фараби, Казахстан, г. Алматы

Сериков Еламан Каиргельдиевич, студент, Казахский Национальный Университет имени Аль-Фараби, Казахстан, г. Алматы

Тулеген Аида Талапқызы, студент, Казахский Национальный Университет имени Аль-Фараби, Казахстан, г. Алматы

Orakov Orynbasar, Student of Al-Farabi Kazakh National University, Kazakhstan, Almaty city, orynbasar1999@gmail.com

Serikov Elaman, Student of Al-Farabi Kazakh National University, Kazakhstan, Almaty city, elamanserikov99@gmail.com

Tulegen Aida, Student of Al-Farabi Kazakh National University, Kazakhstan, Almaty city, aida.tul1602@gmail.com

Аннотация

В этой статье мы рассматриваем проблему многоклассовой классификации на основе выходных кодов с исправлением ошибок, когда отдельные двоичные классификаторы являются моделями глубокого обучения. Мы сосредоточены на вопросе дизайна кодовых книг – наряду с гарантиями оптимальности.

Abstract

In this article, we consider the problem of multi-class classification based on error-correcting output codes when individual binary classifiers are deep learning models. We focus on the design of codebooks - along with optimality guarantees.

Ключевые слова: Многоклассовая классификация, двоичная классификация, машинное обучение, глубокое обучение

Keywords: Multiclass classification, binary classification, machine learning, deep learning

Выходные коды с исправлением ошибок предлагают эффективный и гибкий инструмент для комбинирования индивидуально обученных двоичных классификаторов для многоклассовой классификации. Предыдущие исследования показали, что ECOC могут обеспечить высокую точность многоклассовой классификации с использованием простых, но мощных двоичных классификаторов (например, Support Vector Machines и Adaboost). С другой стороны, в последние годы появился обширный объем работ, показывающих, что:

когда доступен большой объем обучающих данных, модели глубокого обучения превосходят большинство многоклассовых классификаторов. Тем не менее, дальнейший прогресс необходим для задач классификации, когда обучающие данные ограничены и интерпретируемость модели является предпочтительной.

Важно отметить, что наш подход к разработке кодовой книги отличается от предшествующих, в которой проблема решается с помощью непрерывного ослабления изначально дискретной задачи оптимизации и решения упрощенной задачи с использованием инструментов нелинейной оптимизации. В принципе, этот подход можно масштабировать на большое количество классов, но он не дает никаких гарантий оптимальности. Другой подход, описанный в литературе, рассматривает проблему проектирования как проблему пропозициональной выполнимости, которая может быть решена с использованием готовых SAT-решателей. Однако с помощью этого подхода можно легко вычислить только

возможное решение. Напротив, мы формулируем задачу оптимального проектирования кодовой книги как крупномасштабную целочисленную программу (IP) и используем структуру проблемы для получения компактной формулировки, которую можно решить с помощью современных решателей IP. Наша результирующая кодовая книга имеет гарантии оптимальности. Это также дает возможность систематического сравнения по отношению к нескольким хорошо известным кодовым книгам фиксированного размера.

В большинстве проблем классификации с несколькими классами некоторые эксперты применяют функцию softmax для проблемы классификации в целом, в основном заменяя функцию softmax набором бинарных классификаторов SVM, организованных в виде древовидной структуры или DAG (направленный ациклический граф). Следовательно, любая SVM занимается классификации на два класса.

Многоклассовая классификация – одна из самых важных задач в машинном обучении. В нашем случае меняются не ранние уровни сети, а только самые внешние. Таким образом, задача N связана с многоклассовой классификацией в двоичных задачах N (N-1) / 2. Подмена softmax двоичным классификатором в структуре DAG. Это увеличивает корректность, изучая больше попарно различающих функций (рис. 1).

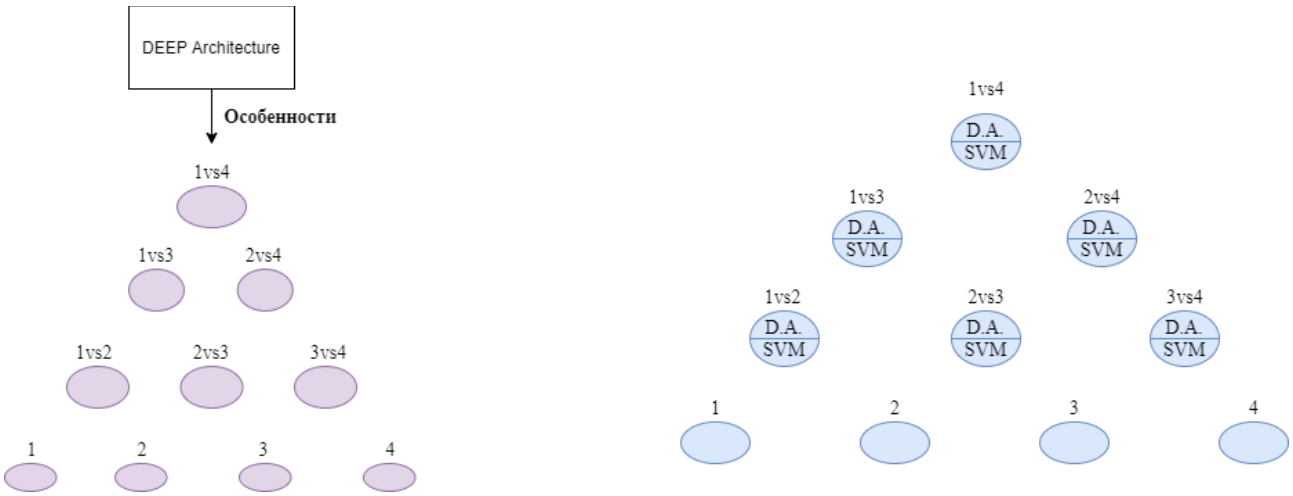

Рисунок 1. Два варианта многоклассовой классификации используя бинарные классификаторы в структуре DAG.

Метод заключается в том, что все классификаторы являются экспертами по отличительным признакам. Благодаря этому конечная точность модели выходит намного больше по сравнению с методом softmax. Также плюсом метода является то, что каждый классификатор можно настроить для последующего повышения точности модели.

Модели	Методы	Точность (%)
A VGG с модификацией	A+Softmax A+DAGSVM A*+DAGSVM	89.07 90.76 92.50
B NIN с модификацией	B+Softmax B+DAGSVM B*+DAGSVM	87.97 90.17 90.95
C ResNet с модификацией	C+Softmax C+DAGSVM C*+DAGSVM	90.98 92.52 93.69

Таблица 1. Результаты точности трех различных моделей

Эксперимент включал три различные модели, чтобы наглядно показать улучшения после использования этого метода. Были использованы сети VGG(A), NIN(B), ResNet(C) с модификацией. Базовая сеть была обучена (с использованием классификации Softmax), последний слой меняется через DAGSVM и заново обучается для увеличения производительности. Таблица 1 показывает точность классификатора, и можно увидеть, что точная конфигурация каждого классификатора очень возможна. В итоге увеличивается производительность всей модели.

В заключение данной статьи был описан способ преобразования задачи многоклассовой классификации в меньшую задачу двоичной классификации. Данный способ не только увеличивает производительность за счет исследования более отличительных функций, но и позволяет точно настроить сеть. Некоторым

лимитированием данного подхода является то, что он невозможен для большого количества классов и не является интегрированной системой обучения.

Литература

1. Lastra-Díaz, J. J., Goikoetxea, J., Hadj Taieb, M. A., García-Serrano, A., Ben Aouicha, M., & Agirre, E. (2019). A reproducible survey on word embeddings and ontology-based methods for word similarity: linear combinations outperform the state of the art. Engineering Applications of Artificial Intelligence, 85, 645-665. doi:10.1016/j.engappai.2019.07.010.
2. [Goodfellow et al., 2015] Goodfellow, I., Shlens, J., and Szegedy, C. (2015). Explaining and harnessing adversarial examples. In International Conference on Learning Representations.
3. [Madry et al., 2018] Madry, A., Makelov, A., Schmidt, L., Tsipras, D., and Vladu, A. (2018). Towards deep learning models resistant to adversarial attacks. ArXiv, abs/1706.06083.
4. Fundamentals of Machine Learning for Predictive Data Analytics, second edition: Algorithms, Worked Examples, and Case Studies 2nd Edition, John D. Kelleher (Author), Brian Mac Namee (Author), Aoife D'Arcy (Author), 2018.
5. Machine Learning: A Bayesian and Optimization Perspective 2nd Edition, Sergios Theodoridis (Author), 2019.
6. Building Machine Learning Pipelines Automating Model Life Cycles with TensorFlow, Hannes Hapke, Catherine Nelson, 2020
7. Machine Learning in Finance from Theory to Practice, Matthew F. Dixon, Igor Halperin, Paul Bilokon, Jul 2, 2020