

Нейросетевое моделирование в задачах диагностики объектов сложной структуры. Проблемы и пути решения*

Ломакина Л.С., Чернобаев И.Д., Двиговская А.Н.

Нижегородский государственный технический университет им. Р.Е. Алексеева

г. Нижний Новгород, Российская Федерация

ichernobnn@gmail.com

Аннотация. В работе рассматривается задача диагностирования технических объектов сложной структуры с позиции классификации проблемных состояний. Задача классификации решается приближенными численными методами. Искусственные нейронные сети как метод машинного обучения, обладают свойством универсального аппроксиматора, и позволяют решать задачи с высокой точностью, но при этом применение нейронных сетей сопровождается трудностями, связанными с необходимостью достаточного объема обучающей выборки, переобучением, сложностью в интерпретации решений. Важным недостатком нейронных сетей является высокая вычислительная сложность алгоритма обучения. Несмотря на это нейронные сети остаются востребованными в области технической диагностики благодаря высокой точности решений. В работе рассматривается подход к ускорению нейронных сетей и повышению точности диагностирования через применение ансамблевых методов машинного обучения. На примере диагностирования микроструктуры поверхности металла рассматривается обучение и применение ансамбля сверточных нейронных сетей. Результаты эксперимента показывают что ансамбль из четырех моделей повышает процент точности прогнозирования проблемных состояний на 4%, следовательно ансамблевые методы машинного обучения повышают точность нейросетевых моделей.

Ключевые слова: диагностика, объекты сложной структуры, ансамблевые методы машинного обучения, нейросетевое моделирование.

ВВЕДЕНИЕ

Продолжительное и непрерывное эксплуатирование технических систем обязательно сопровождается специальными процедурами по анализу их технического состояния, позволяющими своевременно проводить техническое обслуживание для предотвращения износа оборудования и поддержания систем в нормальном рабочем состоянии.

В процессе эксплуатации технических систем неизбежно возникают отклонения от нормального состояния, которые могут привести к снижению функциональных характеристик и впоследствии к отказам, результатами которых могут стать не только простои, сопровождаемые финансовыми потерями, но также и экологические катастрофы и даже гибель людей.

Проблемное состояние (ПС) технической системы характеризуется отклонением признаков или совокупностей признаков от нормальных значений [1]. Отклонения признаков от заданных нормальных значений может быть свя-

зано с износом оборудования, неисправностями, перегрузками или прочими факторами, нарушающими надежное, безопасное и эффективное функционирование технической системы.

Своевременное обнаружение ПС технической системы определяет ключевую задачу технической диагностики [2], при решении которой в рассматриваемом интервале времени анализируются отклонения в параметрах системы и оценивается мера их влияния на нормальное функционирование системы.

В условиях современного технологического развития структура технических объектов становится все более сложной, и при этом повышаются накладные расходы на эксплуатацию, обслуживание и ремонт.

Технические объекты сложной структуры, такие как промышленное оборудование, энергетические комплексы и прочие объекты критической инфраструктуры, включают множество взаимосвязанных компонентов, и при этом неисправность одного компонента может оказаться достаточной для нарушения нормального функционирования всего объекта.

Направления исследований в области технической диагностики связаны с поиском, разработкой и внедрением методов, более эффективных с точки зрения точности и, в особенности, оперативности принятия решений. Современные тенденции в области технической диагностики связаны с применением передовых инструментов машинного обучения ввиду того, что при диагностировании сложных технических объектов часто требуется в режиме реального времени анализировать большие объемы данных и оперативно принимать решения по прогнозированию ПС технических объектов.

В работе рассматриваются подходы к техническому диагностированию с применением инструмента нейросетевого моделирования, преимущества и ограничения искусственных нейронных сетей (ИНС), а также предложены подходы, направленные на повышение точности и оперативности диагностирования ансамблевыми методами машинного обучения.

ПРОГНОЗИРОВАНИЕ ПРОБЛЕМНЫХ СОСТОЯНИЙ

Проблему прогнозирования ПС технической системы можно формализовать как классическую задачу машинного обучения - задачу бинарной классификации, решение которой принадлежит к множеству из двух категорий:

* Статья публикуется по рекомендации программного комитета Всероссийской научно-технической конференции Автоматизация, <https://rusautocon.org>

«нормальное состояние», «критическое состояние». В контексте задачи классификации образ объекта сложной структуры описывается совокупностью взаимосвязанных элементов признакового описания [3].

Задачу классификации можно решать точными аналитическими или приближенными числовыми методами.

Аналитические методы предполагают постановку проблемы и расчет точного решения задачи за прогнозируемое время и конечное число операций. Для применения точных методов анализируемый процесс должен быть четко определен, и при этом точного решения может не существовать. Аналитические методы не имеют фазы обучения, и каждый раз для получения точного решения, при его существовании, выполняют обработку некоторого объема данных, при этом обрабатываемые данные должны быть качественными. Такие методы востребованы в тех областях, где важна интерпретируемость решений, отсутствуют необходимые объемы обучающих данных, а сами данные содержат хорошо известные закономерности.

Поиск оптимального решения численными методами, применяется в случаях, когда точное решение невозможно получить за разумное время ввиду того, что его не существует, оно неизвестно, и при этом существует множество решений допустимых. Численные методы решают задачу оптимизации - поиска оптимального решения в условиях неполных данных, содержащих ошибки и погрешности измерений. Подобные методы востребованы в условиях ограниченных вычислительных ресурсов.

Искусственные нейронные сети (ИНС), как один из методов приближенного поиска решения, позволяют обрабатывать большие объемы данных, выявлять скрытые в них закономерности, которые не поддаются аналитическому решению.

В технической диагностике ИНС применяются для прогнозирования отказов оборудования и диагностирования проблемных состояний технических объектов.

Известно, что ИНС обладают свойствами универсального аппроксиматора [4], обеспечивают высокую точность в прикладных задачах и способны к обобщению новых данных, отсутствующих в обучающем наборе. К основным недостаткам ИНС относят медленное обучение [5], проблемы, связанные с интерпретацией решений, обученных ИНС [6], и переобучением. Переобучение ИНС приводит к снижению обобщающей способности. Для того чтобы исключить переобучение, требуется обеспечить достаточный объем обучающих данных.

Сложность обучения ИНС

Обучение ИНС связано с поиском оптимального решения задачи, а ключевой этап алгоритма обучения, вносящий наибольший вклад в вычислительную сложность процедуры обучения определяется количеством операций в вычислительном графе сети [7]. Вычислительный граф ИНС содержит множество операций с плавающей точкой. К операциям, вносящим значительный вклад в вычислительную сложность графа ИНС, можно прежде всего отнести операции произведения матриц, а также операции вычисления сверток, нормализации и нелинейных функций активации. Размеры матриц, участвующих в операциях вычислительного графа сети, определяются количеством весовых коэффициентов (количеством нейронов) в каждом слое ИНС.

На вычислительную сложность [8] ИНС влияют следующие факторы: количество слоев в модели ИНС обуславливает объем вычислений, выполняемый при прямом распространении сигнала в ИНС и обратном распространении ошибки при обучении, количество нейронов в слое обуславливает размеры матриц весовых коэффициентов и зачастую это влияет на вычислительную сложность в квадратичной форме, объем обучающей выборки и число обучающих эпох также приводят к линейному росту объема вычислений в ИНС. Функции активации, как правило, не требуют значительных вычислительных и не вносят вклад в оценку сложности вычислений в ИНС.

На примере простой ИНС прямого распространения основной объем вычислений определяют операции произведения матриц, операции вычисления функций активации и количество слоев в ИНС. Известно, что простейший алгоритм произведения квадратных матриц выполняет n^3 операций произведения, следовательно его сложность составляет

$$Compl_{mul} = O(n^3) \quad (1)$$

где n - размер матрицы весовых коэффициентов.

Сложность вычисления функции активации линейна, так как зависит от количества нейронов в слое. В общем случае, объем операций в ИНС с учетом количества слоев в модели можно формализовать в виде:

$$n_{ops} = n_{layers} \cdot n_{mul}, \quad (2)$$

следовательно, его сложность алгоритма вычисления ИНС можно оценить, как

$$Compl_{ops} = O(n^4) \quad (3)$$

Ввиду того, что в современных нейросетевых моделях содержатся сотни миллионов и миллиарды параметров [9-12], обучение и применение актуальных на сегодняшний день моделей ИНС сопровождается высокой нагрузкой на вычислительные системы, что увеличивает потребление энергии, и приводит к росту затрат на разработку и применение нейросетевых моделей.

Ускорение ИНС остается актуальной задачей в современном машинном обучении, особенно в контексте их применения в задачах технической диагностики. Существующие подходы к ускорению ИНС включают снижение размеров матриц в обученной ИНС [13], объединение нескольких последовательных операций в одну для выполнения на ускорителе [14], методы квантизации [15] для кратного уменьшения размера ИНС в памяти вычислительной системы, алгоритмы параллельного выполнения [8], позволяющие использовать несколько ускорителей одновременно.

УСКОРЕНИЕ ВЫЧИСЛЕНИЙ В ТЕХНИЧЕСКОЙ ДИАГНОСТИКЕ ЧЕРЕЗ АНСАМБЛЕВЫЕ МЕТОДЫ МАШИННОГО ОБУЧЕНИЯ

Ансамблевые методы машинного обучения [16], позволяют распределять вычислительную нагрузку между несколькими моделями машинного обучения, что не только ускоряет процесс вычисления, но и повышает качество решений.

Ансамблевые модели машинного обучения представляют собой системы, построенные из нескольких независимых прогностических моделей для решения одной задачи. Обучение базовых моделей в ансамбле происходит на одних и тех же обучающих данных. В результате работы ансамбля результаты базовых моделей объединяются в соответствии с заданными правилами. Такой подход позволяет

получить лучшую точность при решении прикладных задач [17] ввиду того, что объединение нескольких базовых моделей в ансамбле приводит к снижению дисперсии.

В отличие от нейросетевого моделирования, где основная задача состоит в получении высокоточной модели ИНС, одна из главных задач разработки ансамбля моделей заключается в том, чтобы получить базовые модели, допускающие ошибки различного рода на одном наборе обучающих данных. На примере решения задачи прогнозирования ансамблевыми методами машинного обучения высокая точность достигается даже при использовании менее точных базовых моделей, допускающих ошибки прогнозирования на обучающих примерах.

Из всего многообразия подходов к объединению базовых моделей в ансамбли для решения задачи прогнозирования ПС, можно выделить три доминирующих метода. Такие подходы к организации ансамблей моделей машинного обучения как Stacking [18], Bagging [19] и Boosting [20], при решении прикладных задач позволяют обеспечить лучшую точность и производительность с точки зрения пропускной способности вычислительной системы, на которой разворачивается ансамбль моделей, но при этом улучшение производительности достигается за счет увеличения вычислительной сложности алгоритма.

Тем не менее, в задачах классификации состояний технических и технологических объектов сложной структуры даже малое повышение точности прогнозирования может оказаться действительно ценным.

В методе построения ансамбля моделей машинного обучения Bagging реализован подход к объединению базовых моделей, обучение которых происходит параллельно, и при этом на различных выборках из исходного набора данных для обучения. Термин «bagging» предложен профессором Калифорнийского университета в Беркли Лео Брейманом и расшифровывается как «bootstrap aggregation». В переводе на русский язык этот термин можно интерпретировать как объединение результатов при различных выборках.

Ансамблевый метод Bagging основывается на статистическом методе bootstrap. Этот метод снижает дисперсию и позволяет исключить вероятность переобучения базовой модели. Эффективность метода обуславливается тем, что базовые модели, обученные по различным выборкам из одного обучающего набора данных, становятся в достаточной степени различными, и при этом их ошибки взаимно компенсируются. Этот обобщенный подход достаточно просто расширить через внесение дополнительных преобразований в исходном наборе обучающих данных или путем модификации механизма объединения прогнозов. Решение ансамбля моделей машинного обучения bagging можно представить в виде:

$$a(x) = \frac{1}{T} \sum_t^T m_t(x) \quad (4)$$

В ансамблевом методе Boosting процедура обработки данных выполняется последовательно: исходный набор обучающих данных подается в первый классификатор, далее прогнозы первого классификатора передаются на вход следующего. Таким образом, в ансамбле каждая следующая базовая модель корректирует ошибки предыдущих. Алгоритм метода boosting можно формализовать в виде:

- 1) Инициализация наблюдений обучающего набора данных одинаковыми весами;
- 2) Обучение базовой модели на данных;
- 3) Добавление в ансамбль полученной базовой модели. Ошибка модели, формализованная как сумма неверных прогнозов также добавляется в ансамбль;
- 4) Вес ошибочных прогнозов для базовой модели ансамбля увеличивается;
- 5) Шаги 2 - 4 повторяются заданное число эпох.

Элементы выборки, в которых один классификатор выдает ошибочные прогнозы, передаются на вход следующего классификатора, задача которого состоит в исследовании проблемных областей пространства признаков и границы области решений предыдущего классификатора. Далее для определения прогноза на выборке тестовых данных определяется решение ансамбля всех классификаторов.

В ансамблевом методе Stacking каждая базовая модель обрабатывает каждый образец из исходной выборки данных, при этом прогнозы базовых моделей впоследствии используются в качестве входных данных для так называемого «мета-классификатора», который выполняет прогнозирование на основе полученных данных от базовых моделей ансамбля.

В прикладных областях диагностирования критически важно применять одновременно точные и быстрые алгоритмы машинного обучения, при этом повышение точности не должно в значимой мере приводить к повышению продолжительности обучения модели и повышению времени ее работы.

Эффективность метода обуславливается тем, что каждая базовая модель обучается различать различные признаки исходного набора данных, при этом ошибки моделей взаимно компенсируются, а дисперсия уменьшается. Поэтому ансамбль таких моделей позволяет достигать высокой точности результатов.

С учетом вышеизложенного, в задаче диагностирования объектов сложной структуры для повышения точности предлагается применить метод ансамблевого машинного обучения Bagging, в котором создается несколько экземпляров базовой модели ИНС. Каждая базовая модель обучается на разных подмножествах из исходной обучающей выборки. Выбранный подход к построению ансамбля моделей машинного обучения позволяет организовать параллельное обучение нескольких базовых моделей в соответствии со схемой, приведенной на рис. 1.

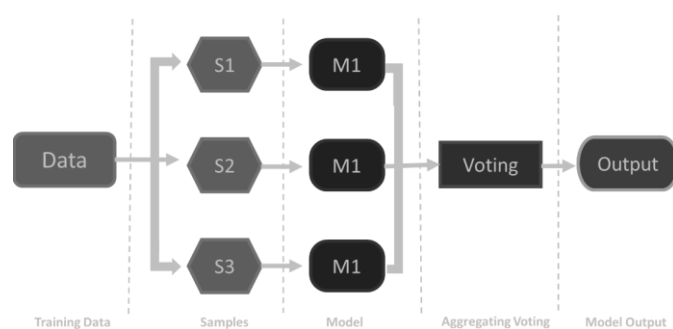


Рис. 1. Схема метода ансамблирования Bagging.

Для успешного применения инструмента нейросетевого моделирования требуется необходимый объем данных, и при этом формирование обучающей выборки является трудоемкой задачей ввиду невозможности автоматизации процедуры сбора и предварительной обработки. В связи с этим становится актуальной проблема получения необходимого объема данных. В условиях нехватки данных для обучения возникает высокая вероятность переобучения моделей, в результате которой нейросетевые модели демонстрируют высокую точность прогнозирования на обучающих данных, но при этом допускают больше ошибок на реальных данных.

В работе предлагается рассмотреть обеспечение работоспособности моделей ИНС в условиях неполных данных через подходы к дополнению (аугментированию) данных. Методы аугментации расширяют набор данных через синтез новых примеров на основании заданных эвристик, при этом базовые модели, обученные на таких данных становятся способными различать большее число признаков в данных за счет повышения обобщающей способности, что приводит к увеличению точности решений.

ДИАГНОСТИРОВАНИЕ МИКРОСТРУКТУРЫ ПОВЕРХНОСТИ МЕТАЛЛА АНСАМБЛЕВЫМ МЕТОДОМ МАШИННОГО ОБУЧЕНИЯ

В работе на примере прикладной задачи анализа микро-структуры поверхности металла [1] рассмотрена модель интеллектуального диагностирования проблемных состояний на основе ансамблевого метода машинного обучения Bagging и сверточных ИНС в роли базовых моделей ансамбля. Схема модели представлена на рис. 2.




Рис. 2. Модель интеллектуального диагностирования проблемных состояний микро-структуры поверхности металлов и сплавов

При обучении нейросетевых моделей на вход ансамбля подаются сформированные в результате предварительной обработки выборки изображений микро-структуры поверхности металла с различной степенью деградации материала. Деградация материала [1] проявляется как результат циклических нагрузок определенного характера, которым подвергается деталь. Чрезмерно большие прикладываемые нагрузки сперва приводят к образованию микроскопических трещин, и впоследствии, когда трещины достигают критического размера, к разрушению детали.

Ансамблевый метод машинного обучения Bagging позволяет реализовать параллельное обучение базовых моделей, следовательно, при использовании достаточно производительной вычислительной системы время обучение ансамбля сопоставимо с временем обучения одной базовой модели.

Схема алгоритма обучения ансамбля базовых моделей проиллюстрирована на рис. 3.

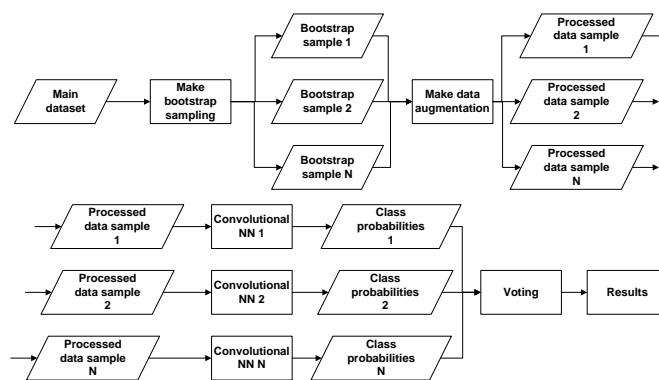


Рис. 3. Алгоритм обучения модели интеллектуального диагностирования проблемных состояний микро-структуры поверхности металлов и сплавов

Обученные базовые модели в ансамбле готовы к обработке новых образцов данных в виде изображений для решения задачи прогнозирования состояний микро-структуры поверхности металлов.

Ансамбль базовых моделей сверточной ИНС обучен на выборке изображений поверхности микро-структуры металла, содержащих пять категорий дефектов, представленных на рис. 4. Общий размер выборки составляет 9000 изображений, размер обучающей выборки составляет 8100 изображений, размер тестовой выборки составляет 900 изображений.




Рис. 4. Категории коэффициентов разрушения металла (0 – отсутствие дефектов в микро-структуре, 1 – разрушение образца)

При решении прикладной задачи прогнозирования дефектов микро-структуры поверхности металла рассмотрено применение разного количества базовых моделей в ансамбле - от одного до десяти. Полученные результаты точности прогнозирования дефектов, в зависимости от количества базовых моделей в ансамбле, представлены на рис. 5.

На рис. 5. показано, что, увеличение количества базовых моделей сверточной ИНС в ансамбле ведет к повышению точности прогнозирования дефектов. Четыре базовые модели в ансамбле позволяют добиться приблизительно 4% повышения точности относительно одной сверточной ИНС. Несмотря на незначительный спад точности для пяти и шести базовых моделей в ансамбле, по-прежнему точность ансамбля выше, чем точность отдельной ИНС. При увеличении числа базовых моделей до десяти, точность ансамбля колеблется около значения 90%. В результате проведенного эксперимента видно, что ансамбль сверточных

ИНС позволяет добиться повышения точности диагностирования дефектов относительно одной модели сверточной ИНС.

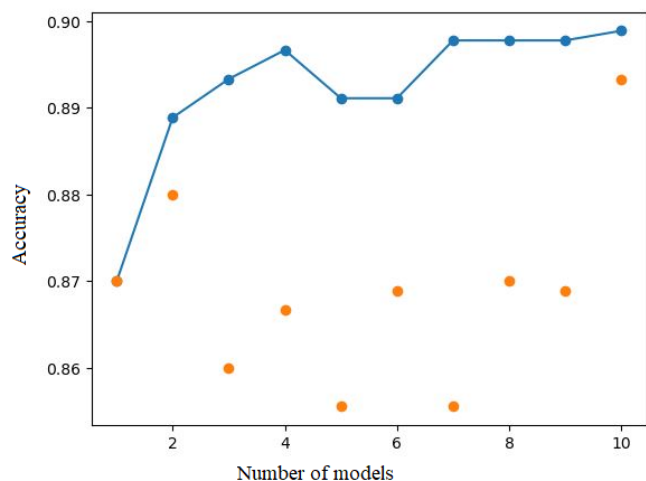


Рис. 5. Результаты работы модели ансамблей размером от 1 до 10 моделей

ЗАКЛЮЧЕНИЕ

В работе рассмотрена задача технической диагностики объектов сложной структуры через прогнозирование проблемных состояний. Инструмент нейросетевого моделирования допускает прикладное применение в любых задачах машинного обучения благодаря свойству универсального аппроксиматора и высокой точности прогнозов, что особенно востребовано в области технического диагностирования. Отмечено, что в рассматриваемой прикладной области важным недостатком ИНС является высокая вычислительная сложность алгоритмов обучения ИНС и работы обученных моделей на реальных данных. В работе показано, что повышение точности ИНС и ускорение обучения и получения решений можно достигнуть через применение ансамблевых методов машинного обучения.

Представленный подход к объединению базовых моделей сверточных ИНС в ансамбль в соответствии с методом Bagging допускает возможность совместного применения произвольного количества базовых моделей ИНС, и при этом подразумевает ускорение вычислений через организацию работы моделей в параллельном режиме на нескольких устройствах вычислительной системы. Применение ансамбля сверточных ИНС в прикладной задаче прогнозирования категории дефекта поверхности микроструктуры металла позволило добиться повышения точности работы до 4% в сравнении с одной моделью сверточной ИНС. Также показано, что значительное увеличение количества базовых моделей не добавляет пропорционального повышения точности прогнозирования ансамбля.

ЛИТЕРАТУРА

1. Манцеров С.А. Системный анализ в интеллектуальном управлении качеством и экобезопасностью состояний технических и технологических объектов. Системный анализ в проектировании и управлении. В 3-х ч. Ч.3 / С.А. Манцеров, Л.С. Ломакина, А.Н. Двиговская // Сборник научных трудов XXVI Международной научно-практиче-

ской конференции, 13–14 октября 2022 г. / Санкт-Петербургский политехнический университет Петра Великого. – СПб.: ПОЛИТЕХ-ПРЕСС, 2023. – С. 85-94

2. Ломакина Л.С. Интеллектуальная прогностика проблемных состояний для объектов сложной структуры / Л.С. Ломакина, С.А. Манцеров, А.Н. Двиговская // Труды Международного научно-технического конгресса «Интеллектуальные системы и информационные технологии - 2023» Научное издание в 2-х т. Т. 1. – Таганрог: Изд-во Ступина С.А., 2023.

3. Ломакина Л.С. Нейро-нечеткие классификаторы. Теория и практика: Монография / Л.С. Ломакина, С.А. Манцеров, И.Д. Чернобаев. – Воронеж: Издательство «Научная книга», 2022. – 137 с.

4. Lu Y. A universal approximation theorem of deep neural networks for expressing probability distributions / Y. Lu, J. Lu // Advances in neural information processing systems. – 2020. – 33:3094-105.

5. Михайлов А.М. Мгновенное обучение при распознавании образов / А.М. Михайлов, М.Ф. Каравай, В.А. Сивцов // Автоматика и телемеханика. – 2022. – №3. – С. 144-155.

6. Saleem R. Explaining deep neural networks: A survey on the global interpretation methods / R. Saleem, B. Yuan, F. Kurugollu, A. Anjum, L. Liu // Neurocomputing. – 2022. – Nov 7;513:165-80.

7. You J. Graph structure of neural networks / J. You, J. Leskovec, K. He, S. Xie // International Conference on Machine Learning. – 2020. – Nov 21. – P. 10881-10891.

8. Freire P. Computational complexity evaluation of neural network applications in signal processing / P. Freire, S. Srivallapanondh, A. Napoli, J.E. Prilepsy, S.K. Turitsyn // arXiv preprint arXiv:2206.12191. – 2022. – Jun 24.

9. Koonce B. In Convolutional neural networks with swift for tensorflow: image recognition and dataset categorization. – 2021. – Jan 5. – P. 63-72.

10. Vedaldi A. Vgg convolutional neural networks practical. Department of Engineering Science / A. Vedaldi, A. Zisserman. – University of Oxford, 2016.

11. Touvron H. Llama: Open and efficient foundation language models / H. Touvron, T. Lavril, G. Izacard, X. Martinet, M.A. Lachaux, T. Lacroix, B. Rozière, N. Goyal, E. Hambro, F. Azhar, A. Rodriguez // arXiv preprint arXiv:2302.13971. – 2023. – Feb 27.

12. Konishi M., Nakano K., Tomoda Y. Efficient Compression of Large Language Models: A Case Study on Llama 2 with 13B Parameters.

13. Hu E.J., Shen Y., Wallis P., Allen-Zhu Z., Li Y., Wang S., Wang L., Chen W. Lora: Low-rank adaptation of large language models. ICLR. 2022 Apr 25;1(2):3.

14. Wang G. Kernel fusion: An effective method for better power efficiency on multithreaded GPU / G. Wang, Y. Lin, W. Yi // In 2010 IEEE/ACM Int'l Conference on Green Computing and Communications & Int'l Conference on Cyber, Physical and Social Computing. – 2010. – Dec 18. – P. 344-350.

15. Gholami A. A survey of quantization methods for efficient neural network inference / A. Gholami, S. Kim, Z. Dong, Z. Yao, M.W. Mahoney, K. Keutzer // Low-power computer vision. – 2022. – Feb 22. – P. 291-326.

16. Galar M. A review on ensembles for the class imbalance problem: bagging-, boosting-, and hybrid-based approaches / M. Galar, A. Fernandez, E. Barrenechea, H. Bustince, F. Herrera // *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*. – 2011. – 42(4). – P.463-484.

17. Bühlmann P. Bagging, boosting and ensemble methods. In *Handbook of computational statistics: Concepts and methods*. – Berlin, Heidelberg: Springer Berlin Heidelberg, 2011. – P. 985-1022.

18. Kwon H. Stacking ensemble technique for classifying breast cancer / H. Kwon, J. Park, Y. Lee // *Healthcare informatics research*. – 2019. – Oct 31., 25(4):283-8.

19. Sun Q. Bagging ensemble selection / Q. Sun, B. Pfahringer // In *AI 2011: Advances in Artificial Intelligence: 24th Australasian Joint Conference, Perth, Australia, December 5-8, 2011*. – P. 251-260.

20. Drucker H. Boosting and other ensemble methods / H. Drucker, C. Cortes, L.D. Jackel, Y. Le Cun, V. Vapnik // *Neural computation*. – 1994. – Nov 6(6):1289-301.

DOI: 10.24892/RIJE/20260108

Neural Network Modeling in the Tasks of Diagnosing Objects of Complex Structure. Problems and Solutions

Lomakina L.S., Chernobaev I.D., Dvitovskaya A.N.
Institute of Radio Electronics and Information Technologies
Nizhny Novgorod State Technical University n.a. R.E. Alekseev
Nizhny Novgorod, Russian Federation
ichernobnn@gmail.com

Abstract. The paper considers the problem of diagnosing technical objects of complex structure from the perspective of classification of problem states. The classification problem is usually solved by numerical methods. Artificial neural networks, as a machine learning approach, have the property of a universal approximation, and allow solving problems with high accuracy, but the use of neural networks is accompanied by difficulties associated with the need for enough training data samples, the risk of model overfitting, and often it is hard to interpret neural network solutions. An important disadvantage of neural networks is the high computational complexity of the learning algorithm. Despite that, neural networks remain in demand in the field of technical diagnostics due to their flexibility and high accuracy. The paper con-

siders an approach to speed up neural networks and improve diagnostic accuracy through the use of ensemble machine learning methods. To demonstrate the approach we train and apply an ensemble of convolutional neural networks to the task of diagnosing the microstructure of a metal surface. The results of the experiment show that an ensemble of four models increases the percentage of accuracy in predicting problematic states by 4%, therefore, ensemble machine learning methods allow increasing the overall accuracy of neural network models.

Keywords: diagnostics, objects of complex structure, ensemble machine learning methods, neural network modeling.

Библиографическое описание статьи

Ломакина Л.С. Нейросетевое моделирование в задачах диагностики объектов сложной структуры. Проблемы и пути решения / Л.С. Ломакина, И.Д. Чернобаев, А.Н. Двитовская // *Машиностроение: сетевой электронный научный журнал*. – 2026. – Т.13, №1. – С. 46-51. DOI: 10.24892/RIJE/20260108

Reference to article

Lomakina L.S., Chernobaev I.D., Dvitovskaya A.N. Neural network modeling in the tasks of diagnosing objects of complex structure. Problems and solutions, *Russian Internet Journal of Industrial Engineering*, 2026, vol.13, no.1, pp. 46-51. DOI: 10.24892/RIJE/20260108