

УДК 629.783; 520.6.05

ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕЙ ПРИ ПРОВЕДЕНИИ МЕТРОЛОГИЧЕСКОЙ ЭКСПЕРТИЗЫ

Воробьев Дмитрий Данилович⁽¹⁾, Низамов Максим Данилович⁽²⁾

Магистр 2 года⁽¹⁾⁽²⁾,

кафедра «Метрология и взаимозаменяемость»

Московский государственный технический университет

Научный руководитель: Е.В. Тумакова,

старший преподаватель кафедры «Метрология и взаимозаменяемость»

Целью данной работы является анализ возможности использования нейросетей при проведении метрологической экспертизы (МЭ).

МЭ является неотъемлемой составной частью метрологического обеспечения (МО) научных исследований, создания/сооружения (исследования и проектирования, разработки, изготовления (производства), поставки, эксплуатации (потребления, хранения), ликвидации) продукции [1]. Она проводится с целью анализа и оценки правильности установления и соблюдения метрологических требований, предъявляемых к объекту, подвергаемому экспертизе.

Основной целью метрологического обеспечения (МО) изделий является обеспечение требуемых норм точности измерений при производстве, испытаниях и эксплуатации.

Основными задачами метрологического обеспечения изделий являются:

- установление в документации требований к МО и контроль их выполнения;
- установление рациональной номенклатуры измеряемых параметров, их допустимых отклонений и требуемой точности измерений;
- установление требований к средствам измерений, их метрологическим характеристикам, порядку их выбора;
- установление оптимальной номенклатуры средств измерений, используемых при создании и эксплуатации системы;
- проведение метрологической экспертизы.

В таблице 1 приведен перечень мероприятий по МО на разных этапах разработки изделий космической техники

Таблица 1 – Перечень мероприятий по МО

Этап	Мероприятие
Этап 1 "Эскизный проект"	Разработка разделов эскизного проекта по метрологическому обеспечению изделий и их СЧ
	Определение основных параметров и тактико-технических характеристик, подлежащих контролю и измерению в процессе изготовления, испытаний и эксплуатации с указанием допускаемых отклонений
	Проработка вопросов обеспечения точности измерений, готовности и достаточности экспериментальной и испытательной баз выполнять измерения с необходимой точностью

Этап	Мероприятие
	Разработка перечня вновь разрабатываемых эталонных и универсальных СИ с указанием требуемых МХ
	Проведение МЭ материалов ЭП и устранение недостатков по ее результатам (План устранения замечаний)
	Выдача смежникам ТЗ на СЧ
	Разработка плана МО изделия
Этап 2 "Разработка РКД для изготовления изделий"	Определение предварительного перечня измеряемых (контролируемых параметров)
	Разработка разделов "Метрологическое обеспечение" в КД и ТД
	Выбор методов (методик) выполнения измерений, обеспечивающих требуемую точность и достоверность контроля
	Согласование документации с метрологической службой
	Разработка перечня измеряемых (контролируемых) параметров и СИ
	Проведение МЭ на этапе РКД
Этап 3 "Изготовление опытного образца и проведение НЭО"	Контроль применения СИ, прошедших процедуру поверки
	Проведение МЭ на этапе РКД и корректировка РКД
Этап 4. "Изготовление ЛО. Участие в комплексных испытаниях в составе КА"	Контроль применения СИ, прошедших процедуру поверки
	Участие в МЭ на этапах ЛИ (при необходимости)
Этап 5 "Корректировка и утверждение РКД."	Корректировка РКД в части МО
	Отработка эксплуатационной документации в части МО устранения замечаний

Некоторые мероприятия проведения МО (такие как: «Проведение МЭ на этапе РКД и корректировка РКД», «Корректировка РКД в части МО», «Отработка эксплуатационной документации в части МО устранения замечаний») подразумевают большую и кропотливую работу с текстом. Проверка рабочей конструкторской документации требует большой концентрации внимания, погружения в контекст, знаний нормативной документации и, что самое главное, большого количества времени (количество дней проверки документации обычно регламентируется нормативной документацией того или иного предприятия, но, как правило, данная процедура занимает несколько дней). Для ускорения процесса проверки и исправления РКД нами была рассмотрена возможность использовать языковые модели для генерации и преобразования текста.

Для выбора определенной модели необходимо решить какие задачи перед нами стоят:

- задача поиска несоответствий в тексте по части метрологического обеспечения;
- задача классификации несоответствий в РКД согласно нормативной документации по части проведения МЭ;
- задача генерации вариантов исправления несоответствий.

Языковые модели делятся на статистические и нейросетевые. В этой статье будет уделено большее внимание нейросетевым моделям, поскольку они хорошо справляются с задачами классификации и генерации текста [2].



Рисунок 1: Языковые модели, рассмотренные в статье.

В основе LLM (от англ. "large language model", далее LLM) лежат нейронные сети — расчетные модели вдохновлен строением и функционированием человеческого мозга. Эти сети состоят из взаимосвязанных узлов или «нейронов», организованных в слои. Каждый нейрон получает входные данные от других нейронов, обрабатывает их и передает результат на следующий слой.

Рекуррентная нейронная сеть (RNN) – это модель глубокого обучения, которая обучена обрабатывать и преобразовывать последовательный набор входных данных в последовательный набор выходных данных. Последовательным набором данных называют такие данные, в которых компоненты имеют строгую упорядоченность и взаимосвязи на основе сложной семантики и синтаксических правил (например, слова, предложения или данные временных рядов). RNN – это программная система из множества взаимосвязанных компонентов, которая квазичеловеческим способом выполняет преобразование последовательных наборов данных, например перевод текста с одного языка на другой. RNN сейчас в значительной степени вытесняются искусственным интеллектом на основе трансформеров и большими языковыми моделями (LLM), которые намного эффективнее выполняют обработку последовательных наборов данных.

Генеративные предобученные трансформеры, широко известные как GPT, представляют собой семейство моделей нейронных сетей, использующих архитектуру трансформеров и являющихся ключевым достижением в области искусственного интеллекта, с помощью которого работают генеративные приложения ИИ, такие как ChatGPT. Модели GPT дают приложениям возможность генерировать текст и контент (изображения, музыку и многое другое), похожий на созданный человеком, и отвечать на вопросы в разговорной манере. Организации из разных отраслей

используют модели GPT и генеративный искусственный интеллект для ботов вопросов и ответов, краткого изложения текста, генерации контента и поиска.

CNN лежали в основе прорывов в классификации изображений — знаменитый AlexNet, победитель соревнования ImageNet в 2012 году, с которого начался бум интереса к этой теме. С тех пор сверточные сети достигли большого успеха в распознавании изображений, в силу того факта, что они устроены наподобие зрительной коры головного мозга — то есть умеют концентрироваться на небольшой области и выделять в ней важные особенности. Но, как оказалось, CNN хороши не только для этого, но и для задач обработки естественного языка (Natural Language Processing, NLP). Более того, в недавно вышедшей статье [3] от коллектива авторов из Intel и Carnegie-Mellon University, утверждается, что они подходят для этого даже лучше RNN, которые безраздельно властвовали областью на протяжении последних лет. В работе [4] авторы классифицируют тексты исходя прямо из букв, выучивая embedding для них в процессе обучения. На больших датасетах они показали даже лучшие результаты, чем сети, работавшие со словами.

Таким образом, применение нейросетей для проведения МЭ в целом возможно, однако требует очень кропотливой "наладки" процессов, связанных с обучением нейросетей, учетом особенностей нормативных документов и пр.

Литература

1. ГОСТ Р 8.1024–2023 Государственная система обеспечения единства измерений. Метрологическая экспертиза технической документации. Основные положения
2. *Богомолов Ю. А.* Обзор моделей нейронных сетей для обработки естественного языка // StudNet. 2020. №4. URL: <https://cyberleninka.ru/article/n/obzor-modeley-neyronnyh-setey-dlya-obrabotki-estestvennogo-yazyka> (дата обращения: 01.04.2024)
3. *Bai, S., Kolter, J. Z., & Koltun, V.* (2018). An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling. URL: arxiv.org/abs/1803.01271 (дата обращения: 03.04.2024)
4. *Heigold, G., Neumann, G., & van Genabith, J.* (2016). Neural morphological tagging from characters for morphologically rich languages. URL: arxiv.org/abs/1606.06640 (дата обращения: 05.04.2024)