

УДК 621.391

## ВОЗМОЖНОСТИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА И МАШИННОГО ОБУЧЕНИЯ В ТЕЛЕКОММУНИКАЦИОННЫХ СЕТЯХ

Д.А. БЕЛЯНКОВ

*Белорусский государственный университет информатики и радиоэлектроники, Республика Беларусь**Поступила в редакцию 31 октября 2019*

**Аннотация.** Телекоммуникационная отрасль всегда сталкивалась со сложными системами, стохастическими контекстами, комбинаторными проблемами и жестким прогнозированием пользователей. В статье представлены некоторые основные концепции машинного обучения и способ их применения в контексте телекоммуникационных сетей, в частности в оптических и беспроводных сетях.

**Ключевые слова:** Оптические сети, беспроводные сети, эталонный формат машинного обучения.

### Введение

К 2021 году глобальный IP-трафик увеличится в три раза по сравнению со значениями 2016 года согласно Индексу визуальных сетевых технологий 2017 года от Cisco [1]. Прогнозируется, что 63 % этого трафика будет происходить с устройств, не относящихся к ПК, что показывает наибольший прирост трафика с планшетов, смартфонов и межмашинных устройств. Таким образом, к 2021 году трафик от беспроводных устройств будет намного выше, чем у проводных. Также значительно увеличится количество устройств, подключенных к Интернету через беспроводную сеть, не только потому, что будет увеличиваться количество смартфонов, планшетов и носимых устройств, но и из-за новых парадигм, таких как «Межмашинные коммуникации» (Machine-to-Machine – M2M) и «Интернет вещей» (Internet of Things – IoT), где все виды электронных устройств будут иметь возможности беспроводной связи. В отчете прогнозируется, что количество подключенных устройств превзойдет человеческое население в три раза. Также важным является тот факт, что большая часть этого приращения трафика будет происходить из-за увеличения видео высокого разрешения (HD), которое будет генерировать увеличение необходимых скоростей передачи данных. В этом контексте разрабатываются сети 5G, чтобы справиться с таким ростом спроса на трафик и скорость передачи данных. Чтобы удовлетворить все эти требования, необходимы новые технологии на всех уровнях сети, от беспроводного доступа к проводной базовой сети и от физических плоскостей и плоскостей данных до плоскостей управления и контроля. Например, срезы сети были недавно введены и тщательно изучаются как средство преодоления неоднородности обслуживания и требований сетей 5G. На этом же уровне такие методы, как виртуализация сетевых функций (Network Function Virtualization – NFV) [2] и программно-определяемые сети (Software Defined Networks – SDN) [3], являются ключевыми инструментами для развертывания 5G. С другой стороны, оптические сети в ядре и на краю сети предлагаются для удовлетворения потребностей с низкой задержкой и высокой скоростью передачи данных. Однако все эти новые технологии, развернутые на разных уровнях и в разных частях сети, должны взаимодействовать друг с другом, чтобы удовлетворить требования пользователей. Более того, требования пользователей будут сильно различаться – от видео приложений с низкой задержкой и высокой скоростью передачи данных до устройств IoT с очень низкими требованиями к производительности. В этом сценарии предполагается, что сети должны будут добавить интеллектуальность и автономность, чтобы адаптироваться к этой огромной

гетерогенности и соответствовать требованиям [4]. Сети с такими характеристиками называются самоорганизующимися сетями (Self-Organizing Networks – SON). В частности, SON – это сеть, которая автономно адаптируется к контексту, чтобы оптимизировать свои цели производительности и может извлекать уроки из среды, а также из своих предыдущих действий. В целом SON делятся на три категории: самоконфигурация, самооптимизация и самовосстановление [4]. Другим фундаментальным аспектом, является тот факт, что доходы операторов сокращаются, поскольку ключевыми игроками являются компании OTT (Over The Top), которые получают выгоду от трафика, генерируемого контентом и приложениями, в частности, WhatsApp, Facebook, YouTube и др.), без инвестиций в сетевую инфраструктуру. В этом сценарии ключевое значение имеет максимальное использование при одновременном реагировании на требования пользователей, и операции на основе искусственного интеллекта имеют решающее значение для достижения этой цели. Проектирование и реализация SON выполняются с помощью двух основных методов: оптимизации и машинного обучения (Machine learning – ML) [4].

Методы оптимизации традиционно использовались в телекоммуникационных сетях и показали отличные результаты в самых разных областях. Однако, в целом, чтобы применить некоторый оптимизационный подход, необходим важный предварительный шаг моделирования и упрощения реальности, который может потребовать значительных объемов работы и привести во многих случаях к неэффективным решениям. Таким образом, после недавнего ажиотажа в области искусственного интеллекта были предложены методы машинного обучения, позволяющие решать самые сложные проблемы, связанные с моделированием реальности. В этой статье выделены некоторые преимущества применения ML.

### **Применение машинного обучения в телекоммуникациях**

Искусственный интеллект (Artificial intelligence – II) – это наука о создании интеллектуальных машин, способных автономно принимать решения на основе воспринимаемой ими среды. Машинное обучение (ML) – ветвь искусственного интеллекта. Как правило, она рассматривается как универсальный инструмент, используемый для задач классификации, определения подходящей категории для нового набора наблюдений и регрессионных задач, оценки взаимосвязи среди выборок данных. Фактически, это разнообразное поле, состоящее из различных компонентов и требующее: программную экосистему, включающую мониторинг и преобразование данных, выбор и оптимизацию моделей, оценку производительности, визуализацию и интеграцию моделей. Очевидно, что ML относится к вычислительному представлению явления, нацеленного на выполнение задачи, дающей определенную производительность и основанной на заданной среде. Подходы ML могут быть классифицированы на основе целей обучения, где они могут быть направлены на идентификацию шаблона для классификации, предсказания, обучение действию или методы индуктивного обучения. Алгоритмы ML могут быть далее классифицированы по трем различным семействам обучения, то есть контролируемому обучению, неконтролируемому обучению и обучению с подкреплением. Полуконтролируемое обучение, или гибридное обучение, иногда считается четвертой ветвью, заимствуя функции из контролируемых и неконтролируемых категорий.

Контролируемое обучение (Supervised learning – SL) [5] использует известные выходные функции, называемые метками, чтобы получить вычислительную связь между входными и выходными данными. Алгоритм итеративно создает модель ML, обновляя ее весовые коэффициенты на основе сопоставления набора входных данных с соответствующими им выходными характеристиками. Кроме того, SL может быть разделено на задачи классификации и регрессии в зависимости от того, используются дискретные или непрерывные выходные характеристики.

Неконтролируемое обучение (Unsupervised learning – USL). В то время как SL обеспечивает чистый подход к построению модели ML, на практике помеченные данные не всегда доступны или доступны в избытке. USL направлено на построение представления заданного набора данных без механизмов обратной связи, управляемых какими-либо метками.

USL может быть далее классифицировано как кластеризация данных в сходные группы или выявление правил ассоциации, идентифицирующих взаимосвязи между функциями.

Обучение с подкреплением (Reinforcement learning – RL) относится к механизмам ML без явной фазы обучения. RL стремится создать и обновить модель ML на основе взаимодействия агента с его собственной средой. Ключевым отличием в отношении SL метода является то, что помеченные функции ввода–вывода не предоставляются, но взаимосвязь скорее изучается посредством применения начальной модели для тестирования данных. Эти методы должны позволять выводить из данных, полученных различными типами мониторов (например, качество сигнала, выборки трафика и т.д.) полезные характеристики, измерение которых затруднено. Некоторые предполагаемые приложения в сети могут включать в себя прогнозирование сбоев, обнаружение вторжений, безопасность, маршрутизацию, низкопрофильное проектирование, реконфигурацию пропускной способности с учетом трафика и многие другие.

### Варианты использования машинного обучения

#### *Инициализация в оптических сетях.*

Эластичная оптическая сеть (Elastic optical networking – EON) использует динамическое и адаптивное обеспечение световых путей для эффективного и гибкого использования сетевых ресурсов. Однако такая гибкость и динамичность требуют схем автоматического обеспечения с надежной оценкой качества передачи (Quality of Transmission – QoT), основанных на реальных условиях сетевых соединений.

Когнитивная многодоменная архитектура эластичной оптической сети, схематическая структура которой показана на рис. 1, работает в соответствии с циклом наблюдения–анализа–действия. Плоскость данных каждого домена оптической сети содержит переключатели с изменяемой полосой пропускания (bandwidth-variable transponders – BVT) и переключатели с полосой пропускания с переменной длиной волны (bandwidth-variable wavelength selectiveswitches – BV-WSSs). Элементы контроля производительности (Performance Monitoring – PM) развертываются в определенных местах для сбора состояния сети в реальном времени (наблюдение). Менеджеры доменов (Domain Managers – DM) применяют парадигму программно-определяемых сетей (software-defined networking – SDN) для управления своими доменами оптической сети [6]. В частности, контроллеры SDN, находящиеся в плоскости контроля и управления доменом, могут собирать данные и осуществлять предоставление услуг, взаимодействуя с агентами программно-определяемых сетей, которые размещаются совместно с оптическими устройствами. На основании технических показателей и полученных PM, DM могут выполнять когнитивное предоставление услуг на уровне домена.

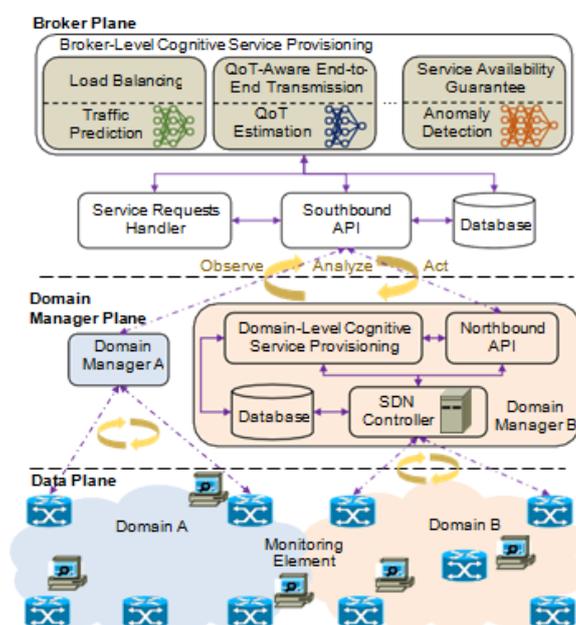


Рис. 1. Схема многодоменной оптической сети

На рис. 2 представлен принцип действия предложенной когнитивной многодоменной оптической сети. Каждый DM постоянно проводит РМ как для внутренних, так и для чужих длин волн. Затем выполняется процесс обучения на уровне домена (этап а). Полученные результаты могут быть использованы либо для внутриобластной инициализации (этап b), либо отправлены в посредническую плоскость для изучения характеристик междоменных сквозных световых трактов (этапы с – d). На этапе инициализации, после приема запроса световода (этап 1), DM сначала определяет, является ли это передачей внутри или между доменами. Если это внутренний запрос, DM немедленно пытается рассчитать решение маршрутизации, формата модуляции и назначения спектра (Routing, Modulation format, and Spectrum Assignment – RMSA), которое удовлетворяет требованию качества передачи. В частности, DM может вычислить несколько путей кандидата, используя RMSA. Затем DM вызывает модель оценки качества передачи на уровне домена для оценки качества передачи каждого возможного решения пути, предоставленного RMSA. DM выберет решение RMSA, которое удовлетворяет требованию качества передачи и обеспечивает качество передачи существующих соединений. С другой стороны, если запрос направлен на междоменную связь, запрос перенаправляется на уровень посредника (этап 2). Для расчета междоменного светового пути плоскость посредника запрашивает внутридоменную информацию от соответствующих DM (этап 3). Каждый вовлеченный DM, в свою очередь, отвечает несколькими внутренними потенциальными световыми путями вместе с их оцененным качеством передачи (этапы 4 и 5). Плоскость посредника агрегирует полученные данные, строит многодоменную виртуальную топологию и вычисляет междоменную сквозную RMSA с гарантией качества, опираясь на модель оценки качества передачи на уровне брокера (шаг 6, с подходом иерархического обучения). Наконец, каждый связанный DM устанавливает сегмент тракта в своем домене для обеспечения услуги междоменной инициализации (этап 8).

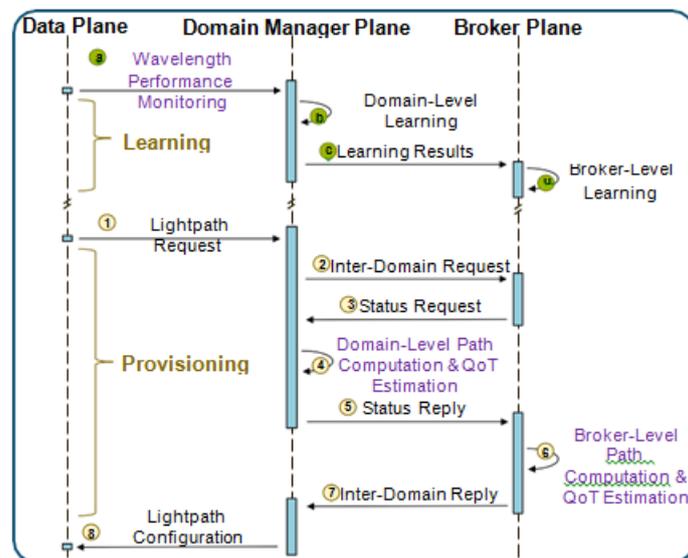


Рис. 2. Принцип действия многодоменной оптической сети с циклом обучения «Наблюдение–анализ–действие» и плоскостью брокера, взаимодействующей с несколькими управляющими доменами

#### *Устойчивость в оптических сетях.*

Локализация отказов – очень полезный метод, поскольку он помогает значительно сократить время восстановления после отказа. Когда в оптическом слое происходит серьезный сбой, измененный трафик должен быть немедленно повторно сохранен с использованием доступных в настоящее время ресурсов [7, 8]. Тем не менее, некоторые серьезные сбои начинаются как мягкие сбои, и они могут быть обнаружены как начальная деградация. Следовательно, желательно предвидеть и устранять серьезные сбои, чтобы планировать правильные действия по изменению маршрута. Несмотря на то, что эволюция некоторых мягких отказов может занять длительное время, они могут влиять на качество световых путей

в нерабочем состоянии. Для выявления мягких отказов, затрагивающих отдельные световые пути, такие как дрейф лазера, смещение фильтра или сжатый свет требуются современные встроенные методы мониторинга для анализа и оценки качества отдельных оптических световых траекторий. В связи с этим, хотя оптико-спектральные анализаторы (Optical Spectrum Analyzers – OSA) можно было использовать для анализа спектра оптических сигналов, до недавнего времени использование OSA в сети было очень ограниченным из-за высокой стоимости точных OSA. Тем не менее, технологии OSA совершенствуются, и в настоящее время новое поколение экономически эффективных анализаторов с разрешением ниже 1 ГГц недоступно для интеграции в оптические узлы нового поколения. Кроме того, OSA и другие системы мониторинга требуют сложных алгоритмов машинного обучения, способных выявлять и локализовать сбои. Эти алгоритмы могут быть развернуты в сетевом контроллере, а также в агентах узлов, близких к точкам мониторинга, чтобы уменьшить объем данных мониторинга, которые должны быть переданы на панель управления. После обнаружения причину сбоя необходимо локализовать с помощью методов пассивного мониторинга, чтобы облегчить перенаправление светового пути. На рис. 3 показано использование OSA для локализации мягких отказов, когда работает световой путь. OSA получают весь спектр C – диапазона, а затем извлекаются данные для части спектра, выделенной исследуемому световому тракту. Пассивный мониторинг OSA осуществляется во входном и каждом промежуточном узле (но не в выходном). Два модуля, работающие в агенте узла, отвечают за анализ спектра: 1) модуль «Извлечение объектов» (Feature Extraction – FeX) – представляет набор соответствующих точек в спектре сигнала, которые используются для вычисления значимых характеристик сигнала; 2) модуль проверки спектра сигнала (Signal Spectrum Verification – SSV), который нацелен на анализ извлеченных признаков для обнаружения неправильной конфигурации, то есть проблем смещения центральной частоты и фильтрации. Алгоритм ML, работающий в сетевом контроллере, отвечает за управление модулями в узлах и получение диагностики, а также соответствующих сигналов от них, чтобы локализовать отказ и оценить его величину. Стоит отметить, что алгоритм ML должен уметь различать фактические сбои и нормальные эффекты, которые могут привести к аналогичным свидетельствам: специфически непроницаемым эффектам фильтрации из-за каскадирования фильтра нормального сигнала. Алгоритм ML использует преимущества модуля сравнения спектра сигналов (Signal Spectrum Comparison – SSC), который генерирует диагностику одного сигнала, фокусирующегося конкретно на проблемах фильтрации. Два полезных алгоритма ML для обнаружения отказов, идентификации и локализации – это классификация и регрессия. При классификации цель состоит в том, чтобы классифицировать неизвестные принятые данные, например, оптический сигнал, и решить, принадлежит ли сигнал нормальному классу, классу FS или классу FT. В регрессии цель состоит в том, чтобы предсказать поведение; например, регрессия может использоваться для оценки величины отказа. Несмотря на то, что несколько алгоритмов ML подходят для одного и того же вывода, выбор лучшего является решением, зависящим от проблемы, где их производительность должна быть изучена для конкретного случая.

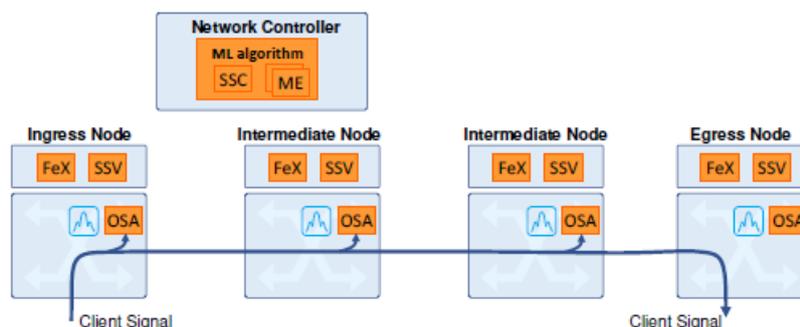


Рис. 3. Пассивный мониторинг OSA для локализации сбоев в работе

#### *Разрезание беспроводных сетей.*

В беспроводных сетях 5G требуется учитывать растущую неоднородность предлагаемых услуг, требований к производительности и технологий связи. В последнее время концепции

разделения сети появились в качестве метода для комплексного управления этими сетями. Разрезание сети состоит в разделении сетевой инфраструктуры на изолированные сегменты сети с собственным набором ресурсов и, возможно, с конкретными требованиями к производительности. Основными заинтересованными сторонами в этой парадигме являются: арендатор, который запрашивает срез и задающий его параметры производительности, и поставщик услуг, который контролирует инфраструктуру и передает ресурсы арендатору. Нарезка классифицируется следующим образом: срезы качества обслуживания (Quality-of-Service Slicing – QoSS), где срезы должны обеспечивать требуемое качество обслуживания, независимо от необходимых ресурсов, и срезы с разделением инфраструктуры (Infrastructure-Sharing Slicing – ISS), где каждому срезу выделяется набор ресурсов для его собственного использования, и он изолируется от остальной части сети. В варианте QoSs поставщик срезов должен удовлетворять запрошенным целям производительности для каждого потока в срезе, в то время как в варианте ISS арендатор требует, чтобы набор ресурсов был зарезервирован для среза. Реализация этих вариантов нарезки в беспроводных сетях представляет несколько проблем и существенно отличается от проводных сетей. В области проводной связи, принято управлять полосой пропускания канала в качестве выделяемого источника. Однако в беспроводных сетях полоса пропускания беспроводной линии связи не фиксирована, поскольку она зависит от характеристик канала. Пропускная способность беспроводной линии связи является переменной и зависит от нескольких факторов, таких как расстояние между узлами, физические препятствия, которые должен пройти сигнал через другие передачи, использующие тот же канал и помехи. Следовательно, в беспроводных сетях ресурсы состоят из радиоспектра (разделенного по времени, частоте или пространству) и времени передачи (эфирное время). В этом сценарии любой механизм, который предлагает управлять и распределять ресурсы, чтобы реализовать нарезку в беспроводных устройствах потребует знания характеристик канала, вероятно, с постоянным мониторингом и с оценкой того, как канал будет вести себя в будущем. Поскольку обстоятельства, влияющие на производительность канала, разнообразны и широки, в общем случае трудно правильно моделировать беспроводной канал. Как следствие, методы машинного обучения являются очень хорошими кандидатами для использования в реализации механизмов предоставления ресурсов для разрезания беспроводных сетей.

### **Заключение**

В этой статье представлены основы машинного обучения и набор вариантов его использования. Рассмотрены две основные технологии физического уровня – оптическая и беспроводная. В случае оптических сетей представлены две наиболее сложные проблемы: обеспечение световых путей надежными требованиями QoT. Для беспроводных сетей исследован другой, но связанный, тип оптимизации: способ оптимизации, при котором сеть может быть «нарезана» или совместно использоваться для сложных аналитических целей. Во всех этих случаях предложено использовать методы машинного обучения, чтобы раскрыть модели воспроизведения, которые были бы слишком сложными, чтобы их можно было понять или сформулировать аналитически. Именно в этом и заключается преимущество машинного обучения. Периодическое человеческое взаимодействие с телекоммуникационными сетями и услугами всех видов содержит скрытые информационные камни, которые при правильной интерпретации позволяют иметь дело с физическими взаимодействиями, которые, на первый взгляд, недоступны. Кроме того, технологии машинного обучения могут быть использованы для выявления взаимодействия этих процессов с использованием пользователей. Промышленность в настоящее время применяет их в широком спектре приложений. Таким образом, машинное обучение позволяет вычислительным системам получать знания из опыта. Эта возможность определяется моделями и правилами, автоматически извлекаемыми из больших объемов данных, а также из постоянного наблюдения за окружающей средой, составления выводов и автоматизации процесса. Тем не менее, следует помнить, что технологии машинного обучения – это ничто иное, как набор алгоритмов, которые можно применить для конкретной функции или модели.

# POSSIBILITIES OF ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING IN TELECOMMUNICATION NETWORKS

D.A. BELIANKOU

**Abstract.** The telecommunications industry has always faced complex systems, stochastic contexts, combinatorial problems and strict user predictions. Some basic machine learning concepts and the way they are applied in the context of telecommunications networks, particularly in optical and wireless networks, were presented.

*Keywords:* Optical networks, wireless networks, reference format of machine learning.

## Список литературы

1. Cisco Visual Networking Index: Forecast and Methodology, 2016–2021. White Paper. Cisco Systems. 2017.
2. Mijumbi R., [et. al.] // Network Function Virtualization: State-of-the-Art and Research Challenges. 2016. P. 236–262.
3. F. Hu, Q. Hao, K. Bao. // IEEE Communications Surveys Tutorials. 2014. P. 2181–2206.
4. Aliu O.G., [et. al.] // A Survey of Self Organisation in Future Cellular Networks. 2013. P. 336–361.
5. Kotsiantis S. B., Zaharakis I., Pintelas P. // Supervised machine learning: A review of classification techniques. Emerging artificial intelligence applications in computer engineering. 2007. P. 3–24.
6. Castro A., [et. al.] // Journal of Lightwave Technology. 2016.
7. Kozat U.C., [et. al.] // IEEE/ACM Transactions on Networking. 2016. P. 2899–2912.
8. Ogino N., Yokota H. // Journal of Lightwave Technology. 2014. P. 467–482.