

Министерство науки и высшего образования Российской Федерации
 федеральное государственное автономное
 образовательное учреждение высшего образования
 «Национальный исследовательский Томский политехнический университет» (ТПУ)

Школа: Инженерная школа природных ресурсов
 Направление подготовки: 21.04.01 Нефтегазовое дело
 Отделение школы (НОЦ): Отделение нефтегазового дела

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ


Тема работы
Применение теории графов при расчете технологических характеристик работы скважин на примере синтетического месторождения SRM-6

УДК 553.98:004.925.84:519.17

Студент

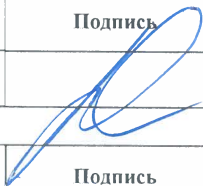
Группа	ФИО	Подпись	Дата
2ТМ91	Вальман Никита Константинович		15.06.21

Руководитель


Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОНД	Матвеев И.В.	к.ф.-м.н.		15.06.21

КОНСУЛЬТАНТЫ:


По разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Рукавишников В.С.	PhD		15.06.21г.

По разделу «Социальная ответственность»

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор	Белозеров В.Б.	д.г.-м.н.		15.06.21

ДОПУСТИТЬ К ЗАЩИТЕ:

Руководитель ООП	ФИО	Ученая степень, звание	Подпись	Дата
Профессор	Чернова О.С.	д.г.-м.н.		15.06.21г.

Томск – 2021 г.

Результаты освоения образовательной программы Универсальные компетенции выпускников и индикаторы их достижения

Категория компетенций	Код и наименование компетенции	Индикаторы достижения компетенции
Системное и критическое мышление	<p>УК-1. Способен осуществлять критический анализ проблемных ситуаций на основе системного анализа, вырабатывать стратегию действий</p>	<p>И.УК(У)-1.1. Анализирует проблемную ситуацию как систему, выявляя ее составляющие и связи между ними</p> <p>И.УК(У)-1.2. Определяет пробелы в информации, необходимой для решения проблемной ситуации, и проектирует процессы по их устранению</p> <p>И.УК(У)-1.3. Разрабатывает стратегию решения проблемной ситуации на основе системного и других современных междисциплинарных подходов; обосновывает выбор темы исследований на основе анализа явлений и процессов в конкретной области научного знания</p> <p>И.УК(У)-1.4. Использует логико-методологический инструментарий для критической оценки современных концепций в своей предметной области</p>
Разработка и реализация проектов	<p>УК(У)-2. Способен управлять проектом на всех этапах его жизненного цикла</p>	<p>И.УК(У)-2.1. Определяет проблему и способ ее решения через реализацию проектного управления</p> <p>И.УК(У)-2.2. Разрабатывает концепцию проекта в рамках обозначенной проблемы: формулирует цель, задачи, обосновывает актуальность, значимость, ожидаемые результаты и возможные сферы их применения</p> <p>И.УК(У)-2.3. Осуществляет мониторинг за ходом реализации проекта, корректирует отклонения, вносит дополнительные изменения в план реализации проекта</p>
Командная работа и лидерство	<p>УК(У)-3. Способен организовывать и руководить работой команды, вырабатывая командную стратегию для достижения поставленной цели</p>	<p>И.УК(У)-3.1. Планирует и корректирует свою социальную и профессиональную деятельность с учетом интересов, особенностей поведения и мнений людей, с которыми работает и взаимодействует</p> <p>И.УК(У)-3.2. Организует дискуссии по заданной теме и обсуждение результатов работы команды</p> <p>И.УК(У)-3.3. Планирует командную работу, распределяет поручения и делегирует полномочия членам команды</p>
Коммуникация	<p>УК(У)-4. Способен применять современные коммуникативные технологии, в том числе на иностранном(ых) языке(ах), для академического и профессионального взаимодействия</p>	<p>И.УК(У)-4.1. Решает конкретные задачи профессиональной деятельности на основе академического и профессионального взаимодействия с учетом анализа мнений, предложений, идей отечественных и зарубежных коллег</p> <p>И.УК(У)-4.2. Составляет, переводит и редактирует различные академические тексты (рефераты, эссе, обзоры, статьи и т.д.)</p> <p>И.УК(У)-4.3. Представляет результаты академической и профессиональной деятельности на различных научных мероприятиях, включая международные</p> <p>И.УК(У)-4.4. Планирует и организывает совещания, деловые беседы, дискуссии по заданной теме; аргументированно и конструктивно отстаивает свою точку зрения, позицию, идею в академических и профессиональных дискуссиях на государственном и иностранном языках</p>
Межкультурное взаимодействие	<p>УК(У)-5. Способен анализировать и учитывать разнообразие культур в процессе межкультурного взаимодействия</p>	<p>И.УК(У)-5.1. Осуществляет профессиональную и социальную деятельность с учетом особенностей поведения и мотивации людей различного социального и культурного происхождения, в том числе особенностей деловой и общей культуры представляе-</p>

Категория компетенций	Код и наименование компетенции	Индикаторы достижения компетенции
Самоорганизация и саморазвитие (в том числе здоровьесбережение)	УК(У)-6. Способен определять и реализовывать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки	лей других этносов и конфессий
		<p>И.УК(У)-5.2. Выстраивает социальное и профессиональное взаимодействие с учётом особенностей деловой и общей культуры представителей разных этносов и конфессий, других социальных групп</p> <p>И.УК(У)-5.3. Обеспечивает создание недискриминационной среды для участников межкультурного взаимодействия при личном общении и при выполнении профессиональных задач</p>
	УК(У)-6. Способен определять и реализовывать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки	И.УК(У)-6.1. Анализирует использование рабочего времени в широком спектре деятельности: планирование, распределение, постановка целей, делегирование полномочий, анализ временных затрат, мониторинг, организация, составление списков и расстановка приоритетов
		И.УК(У)-6.2. Сочетает выполнение текущих производственных задач с повышением квалификации; корректирует планы в соответствии с имеющимися ресурсами
		И.УК(У)-6.3. Планирует профессиональную траекторию с учетом особенностей как профессиональной, так и других видов деятельности и требований рынка труда

5.2. Общепрофессиональные компетенции выпускников и индикаторы их достижения

Категория компетенций	Код и наименование компетенции	Индикаторы достижения компетенции
Применение фундаментальных знаний	ОПК-1. Способен решать производственные и (или) исследовательские задачи на основе фундаментальных знаний в нефтегазовой области	И.ОПК(У)-1.1. Демонстрирует навыки физического и программного моделирования отдельных фрагментов процесса выбора оптимального варианта для конкретных условий
Техническое проектирование	ОПК(У)-2. Способен осуществлять проектирование объектов нефтегазового производства	И.ОПК(У)-1.2. Использует фундаментальные знания профессиональной деятельности для решения конкретных задач нефтегазового производства
		И.ОПК(У)-1.3. Анализирует причины снижения качества технологических процессов и предлагает эффективные способы повышения качества производства работ при выполнении различных технологических операций
	ОПК(У)-3. Способен разрабатывать научно-техническую, проектную и служебную документацию, оформлять научные отчеты, обзоры, публикации, рецензии	И.ОПК(У)-2.1. Использует знание алгоритма организации выполнения работ в процессе проектирования объектов нефтегазовой отрасли
		И.ОПК(У)-2.2. Формулирует цели выполнения работ и предлагает пути их достижения
Работа с информацией	ОПК(У)-4. Способен находить и перерабатывать информацию, требуемую для принятия решений в научных исследованиях и в практической технической деятельности	И.ОПК(У)-2.3. Выбирает соответствующие программные продукты или их части для решения конкретных профессиональных задач
		И.ОПК(У)-3.1. Анализирует информацию и составляет обзоры, отчеты
	И.ОПК(У)-3.2. Владеет навыками аналитического обзора при подготовке рефератов, публикаций и не менее 50 источников при подготовке магистерской диссертации	
	И.ОПК(У)-4.1. Определяет основные направления развития инновационных технологий в нефтегазовой отрасли	
	И.ОПК(У)-4.2. Обрабатывает результаты научно-исследовательской, практической	

				технической деятельности, используя имеющиеся оборудование, приборы и материалы
Исследование	ОПК(У)-5. Способен оценивать результаты научно-технических разработок, научных исследований и обосновывать собственный выбор, систематизируя и обобщая достижения в нефтегазовой отрасли и смежных областях			И.ОПК(У)-5.1. Определяет на профессиональном уровне особенности работы различных типов оборудования и выявление недостатков в его работе И.ОПК(У)-5.3. Интерпретирует результаты лабораторных и технологических исследований применительно к конкретным условиям
Интеграция науки и образования	ОПК(У)-6. Способен участвовать в реализации основных и дополнительных профессиональных образовательных программ, используя специальные научные и профессиональные знания			И.ОПК(У)-6.1. Демонстрирует знания основ педагогики и психологии И.ОПК(У)-6.2. Демонстрирует умение общаться с аудиторией, заинтересовать слушателей

Профессиональные компетенции выпускников и индикаторы их достижения

Область и сфера профессиональной деятельности	Задача профессиональной деятельности	Основание - профессиональный стандарт, анализ опыта, форсайт	Код и наименование компетенции	Индикаторы достижения компетенции
Тип задач профессиональной деятельности: Научно-исследовательский				
19. Добыча, переработка, транспортировка нефти и газа 40. Сквозные виды профессиональных стандартов	1. Осуществление научных исследований в области профессиональной деятельности	<i>Профессиональный стандарт «Специалист по добыче нефти, газа и газового конденсата», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 03 сентября 2018г. № 574н (зарегистрирован Министерством юстиции Российской Федерации 24 сентября 2018 г., регистрационный №52235);</i> <i>ОТФ. Код D. Организация работ по добыче углеводородного сырья</i>	ПК -1. Способен проводить анализ и обобщение научно-технической информации по теме исследования, осуществлять выбор методики и средств решения задачи, проводить патентные исследования в выбранной области нефтегазового инжиниринга	И.ПК-1.1. Анализирует и обобщает научно-техническую информацию по теме исследования, осуществляет выбор методики и средств решения задачи, проводит патентные исследования в выбранной области нефтегазового инжиниринга
	2. Разработка и внедрение новой техники и передовых технологий на объектах нефтегазовой отрасли	19.021 <i>Профессиональный стандарт «Специалист по промысловой геологии», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 10.03.2015 г. № 151н (зарегистрирован Министерством юстиции Российской Федерации 31.03.2015 г. № 36656)</i> <i>ОТФ. Код В. Организация геолого-промысловых работ</i> <i>Профессиональный стандарт «Специалист-петрофизик», утвержденный приказом Минни-</i>	ПК-2. Способен планировать и проводить аналитические, имитационные и экспериментальные исследования, критически оценивать данные и делать выводы	И.ПК-2.1. Планирует и проводит аналитические, имитационные и экспериментальные исследования, критически оценивает данные и делает выводы
			ПК-3. Способен использовать профессиональные программные комплексы в области математического и геолого-геофизического моделирования технологических процессов и объектов	И.ПК-3.1. Использует профессиональные программные комплексы в области математического и геолого-геофизического моделирования технологических процессов и объектов

Область и сфера профессиональной деятельности	Задача профессиональной деятельности	Основание - профессиональный стандарт, анализ опыта, форсайт	Код и наименование компетенции	Индикаторы достижения компетенции
		<p>стерства труда и социальной защиты Российской Федерации от 29 июня 2017 г. N 534н (зарегистрирован Министерством юстиции Российской Федерации 13 июля 2017 г., регистрационный №47411).</p> <p><i>ОТФ. Код С. Организация процесса исследований физических свойств кернового материала нефтегазовых месторождений и цифровой обработки полученных петро-физических данных</i></p> <p><i>Профессиональный стандарт «Специалист-петрофизик», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 29 июня 2017 г. N 534н (зарегистрирован Министерством юстиции Российской Федерации 13 июля 2017 г., регистрационный №47411)</i></p> <p><i>ТФ. Код С01.7. Разработка плановой и проектно-сметной документации на объекты исследований физических свойств кернового материала горных пород и цифровую обработку полученных петрофизических данных</i></p> <p><i>Профессиональный стандарт «Специалист по организации и управлению научно-исследовательскими и опытно-конструкторскими работами», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 11 февраля 2014 г. N 86н (зарегистрирован Министерством юстиции Российской Федерации 21 марта 2014 г., регистрационный №31696)</i></p> <p><i>ОТФ. Код D. Осуществление руко-</i></p>	<p>ПК-10. Способен разрабатывать документацию, планировать и выполнять исследования физических свойств кернового материала осадочных горных пород и цифровую обработку полученных петрофизических данных</p> <p>ПК-10. Способен разрабатывать документацию, планировать и выполнять исследования физических свойств кернового материала осадочных горных пород и цифровую обработку полученных петрофизических данных</p> <p>ПК-11. Способен организовывать и выполнять научно-исследовательские работы в соответствии с тематическим планом организации</p>	<p>И.ПК-10.1. Разрабатывает документацию, планирует и выполняет исследования физических свойств кернового материала осадочных горных пород и цифровую обработку полученных петрофизических данных</p> <p>И.ПК-10.1. Организовывает и выполняет плановые задания по исследованию физических свойств кернового материала горных пород и обработку полученных петрофизических данных</p> <p>И.ПК-10.2. Организовывает и выполняет плановые задания по исследованию физических свойств кернового материала горных пород и обработку полученных петрофизических данных</p> <p>И.ПК-11.1. Организовывает и выполняет научно-исследовательские работы в соответствии с тематическим планом организации</p>

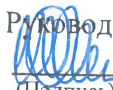
Область и сфера профессиональной деятельности	Задача профессиональной деятельности	Основание - профессиональный стандарт, анализ опыта, форсайт	Код и наименование компетенции	Индикаторы достижения компетенции
		<p>водства разработкой комплексных проектов на всех стадиях и этапах выполнения работ <i>ТФ. Код. D/01/7.</i> Организация выполнения научно-исследовательских работ в соответствии с тематическим планом организации</p>		
Тип задач профессиональной деятельности: Технологический				
<p>19 «Добыча, переработка, транспортировка нефти и газа»</p> <p>40. Сквозные виды профессиональных стандартов</p>	<p>Осуществление контроля, технического сопровождения и управления технологическими процессами нефтегазового производства</p>	<p><i>Профессиональный стандарт «Специалист по добыче нефти, газа и газового конденсата», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 03 сентября 2018г. № 574н (зарегистрирован Министерством юстиции Российской Федерации 24 сентября 2018 г., регистрационный №52235)</i> <i>ОТФ. Код D.</i> Организация работ по добыче углеводородного сырья <i>ОТФ. Код E.</i> Руководство работами по добыче углеводородного сырья</p>	<p>ПК-4. Способен анализировать и обобщать данные о работе технологического оборудования, осуществлять контроль, техническое сопровождение и управление технологическими процессами в нефтегазовом инжиниринге</p>	<p>И.ПК-4.1. Анализирует и обобщает данные о работе технологического оборудования, осуществляет контроль, техническое сопровождение и управление технологическими процессами в нефтегазовом инжиниринге</p>
	<p>Разработка и внедрение новой техники и передовых технологий на объектах нефтегазовой отрасли</p>		<p>ПК-7. Способен контролировать выполнение требований и регламентов для обеспечения добычи нефти, газа и газового конденсата</p>	<p>И.ПК-7.1. Контролирует выполнение требований и регламентов для обеспечения добычи нефти, газа и газового конденсата</p>
			<p>ПК-5. Способен участвовать в управлении технологическими комплексами, принимать решения в условиях неопределенности</p>	<p>И.ПК-5.1. Участвует в управлении технологическими комплексами, принимает решения в условиях неопределенности</p>
Тип задач профессиональной деятельности: Организационно-управленческий				
<p>19 «Добыча, переработка, транспортировка нефти и газа»</p> <p>40. Сквозные виды профессиональных стандартов</p>	<p>Осуществление маркетинговых исследований, проведение технико-экономических расчетов в производственных решениях в промышленности, управление коллективом, руководство производственной деятельностью подразделения</p>	<p><i>Профессиональный стандарт «Специалист по добыче нефти, газа и газового конденсата», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 03 сентября 2018г. № 574н (зарегистрирован Министерством юстиции Российской Федерации 24 сентября 2018 г., регистрационный №52235)</i></p>	<p>ПК-6. Способен осуществлять руководство по организации производственной деятельности подразделения нефтегазового инжиниринга, применять полученные знания для разработки и реализации проектов различных процессов производственной деятельности, применять методику проектирования</p>	<p>И.ПК-6.1. Осуществляет руководство по организации производственной деятельности подразделений нефтегазового инжиниринга</p> <p>И.ПК-6.2. Применяет полученные знания для разработки и реализации проектов различных процессов производственной деятельности, применяет методику проектирования</p>

Область и сфера профессиональной деятельности	Задача профессиональной деятельности	Основание - профессиональный стандарт, анализ опыта, форсайт <i>ТФ. Код E/01.7.</i> Руководство организацией процесса добычи углеводородного сырья	Код и наименование компетенции	Индикаторы достижения компетенции
		<p><i>Профессиональный стандарт «Специалист по промысловому геологии», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 10 марта 2015 г. N 151н (зарегистрирован Министерством юстиции Российской Федерации 31 марта 2015 г., регистрационный №36656)</i></p> <p><i>ОТФ. Код В.</i> Организация геолого-промысловых работ</p> <p><i>ТФ. Код В/02.7.</i> Подготовка предложений по дополнительным геолого-промысловым исследованиям для эффективной работы промысла</p>	<p>ПК-8. Способен подготавливать предложения по дополнительным геолого-промысловым исследованиям для эффективной работы промысла</p>	<p>И.ПК-8.1. Подготавливает предложения по дополнительным геолого-промысловым исследованиям для эффективной работы промысла</p>
	<p>Разработка оперативных планов и руководств по введению всех видов деятельности, связанной с исследованием, разработкой и реализацией управления технологическими процессами и производствами</p>	<p><i>Профессиональный стандарт «Специалист по добыче нефти, газа и газового конденсата», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 03 сентября 2018г. № 574н (зарегистрирован Министерством юстиции Российской Федерации 24 сентября 2018 г., регистрационный №52235)</i></p> <p><i>ТФ. Код E/01.7.</i> Руководство организацией процесса добычи углеводородного сырья</p>	<p>ПК-6. Способен осуществлять руководство по организации производственной деятельности подразделений нефтегазового инжиниринга, применять полученные знания для разработки и реализации проектов различных процессов производственной деятельности, применять методику проектирования</p>	<p>И.ПК-6.2. Применяет полученные знания для разработки и реализации проектов различных процессов производственной деятельности, применяет методику проектирования</p>
		<p><i>Профессиональный стандарт «Специалист по обработке и интерпретации скважинных геофизических данных», утвержденный приказом Министерства труда и социальной защиты Российской Федерации от 10 марта 2015 г. N 151н (зарегистрирован Министерством юстиции Российской Федерации 31 марта 2015 г., регистрационный №36656)</i></p>	<p>ПК-9. Способен разрабатывать перспективные планы в области обработки и интерпретации скважинных геофизических данных, руководить производственно-технологическим процессом обработки и интерпретации скважинных</p>	<p>И.ПК-9.1. Разрабатывает перспективные планы в области обработки и интерпретации скважинных и полевых геофизических данных</p>

Область и сфера профессиональной деятельности	Задача профессиональной деятельности	Основание - профессиональный стандарт, анализ опыта, форсайт	Код и наименование компетенции	Индикаторы достижения компетенции
		<p>Федерации от 28 декабря 2015 г. N 1166н (зарегистрирован Министерством юстиции Российской Федерации 29 июня 2017 г., регистрационный №47457).</p> <p><i>ОТФ. Код D.</i> Управление процессом обработки и интерпретации полученных скважинных геофизических данных</p> <p><i>ТФ. Код D017.</i> Управление разработкой перспективных планов области обработки и интерпретации скважинных геофизических данных</p>	<p>геофизических данных</p>	<p>И.ПК-9.2. Руководит производственно-технологическим процессом обработки и интерпретации скважинных и полевых геофизических данных</p>

Министерство науки и высшего образования Российской Федерации
 федеральное государственное автономное
 образовательное учреждение высшего образования
 «Национальный исследовательский Томский политехнический университет» (ТПУ)

Школа: Инженерная школа природных ресурсов
 Направление подготовки: 21.04.01 Нефтегазовое дело
 Отделение школы: Отделение нефтегазового дела

УТВЕРЖДАЮ:
 Руководитель ООП
 15.03.21 О.С. Чернова
 (Подпись) (Дата)

ЗАДАНИЕ
на выполнение выпускной квалификационной работы

В форме:

Магистерской диссертации

Студенту:

Группа	ФИО
2ТМ91	Вальман Никита Константинович

Тема работы:

Применение теории графов при расчете технологических характеристик работы скважин на примере синтетического месторождения SRM-6

Утверждена приказом директора (дата, номер)

02.03.2021 г. № 61-6/с

Срок сдачи студентом выполненной работы:

15.06.2021г.

ТЕХНИЧЕСКОЕ ЗАДАНИЕ:

Исходные данные к работе	<p><i>Синтетическая модель SRM-6, содержащая в себе как информацию по скважинам, так частично результаты геофизических и гидродинамических исследований, характеристика отбора керна, фильтрационно-емкостные свойства керна.</i></p> <p><i>Фондовая и периодическая литература, учебники, монографии.</i></p>
Перечень подлежащих исследованию, проектированию и разработке вопросов	<ol style="list-style-type: none"> 1 Введение 2 Геологическая характеристика модели SRM-6 3 Нейронные сети и их разновидности 4 Применение теории графов при расчете технологических характеристик работы скважин 5 Финансовый менеджмент, ресурсоэффективность и ресурсосбережение

	<p>6 Социальная ответственность 7 Заключение</p>
<p>Перечень графических материалов</p>	<p><i>Рисунки:</i> <i>Рисунок 1.1 — Общий вид геологической модели SRM-6</i> <i>Рисунок 1.2 — Карта средней пористости</i> <i>Рисунок 1.3 — Карта средней проницаемости</i> <i>Рисунок 1.4 — Карта нефтенасыщенных тощин</i> <i>Рисунок 1.5 — Гистограммы распределения</i> <i>Рисунок 1.6 — Модель после адаптации</i> <i>Рисунок 2.1 — Пример нейронной сети</i> <i>Рисунок 2.2 — Пример показывающий взаимосвязь потерь и значений весов между значениями</i> <i>Рисунок 2.3 — Простой граф</i> <i>Рисунок 2.4 — Граф А</i> <i>Рисунок 2.5 — Граф Б</i> <i>Рисунок 2.6 — Пример гигантского графа</i> <i>Рисунок 2.7 — Иллюстрация обновления состояния узла на основе информации о его соседях</i> <i>Рисунок 2.8 — Свертка графов</i> <i>Рисунок 2.9 — Пример графа с характеристикой, назначенной каждому узлу</i> <i>Рисунок 2.10 — Пример матрицы смежности и матрицы признаков</i> <i>Рисунок 2.11 — Пример свертки графа умножением матриц</i> <i>Рисунок 2.12 — Создание графа сцены</i> <i>Рисунок 2.13 — Изображение сгенерировано из графов сцены</i> <i>Рисунок 2.14 — Распознавание нулевого выстрела через семантические вложения и графы знаний</i> <i>Рисунок 3.1 — Модель до пере-обозначения</i> <i>Рисунок 3.2 — Модель после пере-обозначения</i> <i>Рисунок 3.3 — Сигмоида или функция активации</i> <i>Рисунок 3.4 — Функция потерь процесса обучения и проверки</i> <i>Рисунок 3.5 — Сравнение показателей прогнозируемых дебитов и истинных показателей.</i> <i>Рисунок 4.1 — Комплектация рабочего места</i> <i>Рисунок 4.2 — HYPERPC NANO X</i> <i>Рисунок 5.1 — Схема рабочего места на ПК</i> <i>Рисунок 5.2 — Регулировка офисного стула</i> <i>Рисунок 5.3 — Правильное положение руки на мышке</i> <i>Рисунок 5.4 — Правильное положение руки на клавиатуре</i> <i>Таблицы:</i> <i>Таблица 3.1 — Статические параметры по шести скважинам</i></p>

	<p>Таблица 3.2 — Распределение пористости по слоям между скважинами</p> <p>Таблица 3.3 — Распределение проницаемости по слоям между скважинами</p> <p>Таблица 3.4 — Распределение начальной водонасыщенности по слоям между скважинами</p> <p>Таблица 4.1 — Сравнение требуемых ресурсов между вариантами</p> <p>Таблица 4.2 — Экономические затраты традиционной опции</p> <p>Таблица 4.3 — Экономические затраты предлагаемой опции</p> <p>Таблица 4.4 — Экономия при переходе на предлагаемую опцию</p> <p>Таблица 5.1 — Размерная таблица с рекомендациями по регулировке высоты кресла и стола</p>
--	---

Консультанты по разделам выпускной квалификационной работы


Раздел	Консультант
«Социальная ответственность»	Белозеров В. Б., профессор, д.г.-м.н.
«Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»	Рукавишников В. С., доцент, PhD

Названия разделов, которые должны быть написаны на русском и иностранном языках:


3 Нейронные сети и их разновидности / Application of graph theory in the calculation of technological characteristics of wells on the example of the synthetic field SRM-6

Дата выдачи задания на выполнение выпускной квалификационной работы по линейному графику	15.03.2021
--	------------

Задание выдал руководитель / консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОНД	Матвеев И.В.	к.ф.-м.н.		15.03.2021

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
2ТМ91	Вальман Никита Константинович		15.03.2021

Министерство науки и высшего образования Российской Федерации
 федеральное государственное автономное
 образовательное учреждение высшего образования
 «Национальный исследовательский Томский политехнический университет» (ТПУ)

Школа: Инженерная школа природных ресурсов
 Направление подготовки: 21.04.01 Нефтегазовое дело
 Уровень образования: магистратура
 Отделение школы: Отделение нефтегазового дела
 Период выполнения (осенний / весенний семестр 2020 /2021 учебного года)
 Форма представления работы:

Магистерская диссертация

КАЛЕНДАРНЫЙ РЕЙТИНГ-ПЛАН


выполнения выпускной квалификационной работы

Срок сдачи студентом выполненной работы:	15.06.2021г.
--	--------------

Дата контроля	Название раздела (модуля) / вид работы (исследования)	Максимальный балл раздела (модуля)
27.03.2021	<i>Геологическая характеристика месторождения</i>	15
19.04.2021	<i>Нейронные сети и их разновидности</i>	20
29.04.2021	<i>Application of graph theory in the calculation of technological characteristics of wells on the example of the synthetic field SRM-6</i>	10
04.05.2021	<i>Применение теории графов при расчете технологических характеристик работы скважин</i>	25
21.05.2021	<i>Финансовый менеджмент, ресурсоэффективность и ресурсосбережение</i>	15
28.05.2021	<i>Социальная ответственность</i>	15


СОСТАВИЛ:

Руководитель ВКР

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОНД	Матвеев И.В.	к.ф.-м.н.		15.06.2021г

СОГЛАСОВАНО:

Руководитель ООП

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор	Чернова О.С.	д.г.-м.н.		15.06.2021г

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И
РЕСУРСОСБЕРЕЖЕНИЕ»**

Студенту:

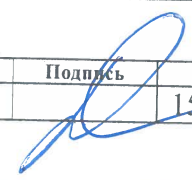
Группа 2ТМ91	ФИО Вальман Никита Константинович
-----------------	--------------------------------------

Школа	ИШПР	Отделение (НОЦ)	ОНД
Уровень образования	Магистратура	Направление/специальность	21.04.01 Нефтегазовое дело


Исходные данные к разделу «Финансовый менеджмент, ресурсоэффективность и ресурсосбережение»:	
1. <i>Стоимость ресурсов научного исследования (НИ): материально-технических, энергетических, финансовых, информационных и человеческих</i>	<i>Стоимость ресурсов для выполнения геологических и гидродинамических моделей.</i>
Перечень вопросов, подлежащих исследованию, проектированию и разработке:	
1. <i>Оценка коммерческого и инновационного потенциала НТИ</i>	<i>Технико-экономическое обоснование целесообразности внедрения новой технологии выполнено на основании данных о стоимости процесса выполнения работы.</i>
2. <i>Определение ресурсной, финансовой, экономической эффективности</i>	<i>Расчёт экономического эффекта: экономия затрат при выполнении излагаемым в работе методом.</i>
Перечень графического материала (с точным указанием обязательных чертежей):	
1. <i>Комплектация рабочего места</i>	
2. <i>HYPERPC NANO X</i>	

Дата выдачи задания для раздела по линейному графику	15.03.2021
--	------------

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент	Рукавишников В.С.	PhD		15.03.2021

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
2ТМ91	Вальман Никита Константинович		15.03.2021

**ЗАДАНИЕ ДЛЯ РАЗДЕЛА
«СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ»**

Студенту:

Группа	ФИО
2ТМ91	Вальман Никита Константинович


Школа	ИШПР	Отделение (НОЦ)	ОНД
Уровень образования	Магистратура	Направление/специальность	21.04.01 Нефтегазовое дело

Исходные данные к разделу «Социальная ответственность»:	
<p>1. Описание рабочего места (рабочей зоны, технологического процесса, используемого оборудования) на предмет возникновения:</p> <ul style="list-style-type: none"> - вредных проявлений факторов производственной среды (метеоусловия, вредные вещества, освещение, шумы, вибрации, электромагнитные поля, ионизирующие излучения и т.д.) - опасных проявлений факторов производственной среды (механической природы, термического характера, электрической, пожарной природы) - чрезвычайных ситуаций социального характера 	<p>Трудовым пространством при выполнении работы считается стол, оснащенный индивидуальным компьютерной станцией. При выполнении работы на организм человека воздействует шум, излучение от экрана монитора, вполне вероятно наличие недостаточной освещенности, отклонений локального климата здания от подходящих характеристик. Также при работе нужно принимать во внимание интенсивность труда. Существует риск поражения электрический ток при выполнении работы.</p>
<p>2. Список законодательных и нормативных документов по теме</p>	<ul style="list-style-type: none"> - СанПиН 2.2.2/2.4.1340 – 03. «Гигиенические требования к персональным электронно-вычислительным машинам и организации работы»; - СанПиН 2.2.4.548-96 «Гигиенические требования к микроклимату производственных помещений»; - ГОСТ 12.0.003-2015 «Система стандартов безопасности труда»; - ТОИ Р-45-084-01 «Типовая инструкция по охране труда при работе на персональном компьютере»; - ПОТ РО-14000-006-98 «Работы с повышенной опасностью»
<p>Перечень вопросов, подлежащих исследованию, проектированию и разработке:</p>	
<p>1 Анализ выявленных вредных факторов проектируемой производственной среды в следующей последовательности:</p> <ul style="list-style-type: none"> - физико-химическая природа вредности, её связь с разрабатываемой темой; - действие фактора на организм человека; 	<p>Работа за компьютером характеризуется влиянием на организм человека следующих вредных факторов производственной среды:</p> <ol style="list-style-type: none"> 1) повышенный уровень шума; 2) недостаточная освещенность рабочей


<ul style="list-style-type: none"> - приведение допустимых норм с необходимой размерностью (со ссылкой на соответствующий нормативно-технический документ); - предлагаемые средства защиты (сначала коллективной защиты, затем – индивидуальные защитные средства) 	<p>зоны;</p> <p>3) повышенный уровень электромагнитных излучений;</p> <p>4) напряженность труда;</p> <p>5) отклонение показателей микроклимата;</p> <p>Основными принципами минимизации воздействия на организм человека вышеизложенных факторов являются соблюдение режима труда и отдыха, использование сертифицированного и исправного оборудования, соблюдение правил использования оборудования, поддержание комфортных условий труда в помещении.</p>
<p>2 Анализ выявленных опасных факторов проектируемой производственной среды в следующей последовательности:</p> <ul style="list-style-type: none"> - механические опасности (источники, средства защиты); - термические опасности (источники, средства защиты); - электробезопасность (в т.ч. статическое электричество, молниезащита – источники, средства защиты); - пожаровзрывобезопасность (причины, профилактические мероприятия, первичные средства пожаротушения). 	<p>Опасным фактором, характеризующим работу за индивидуальным компьютером, считается электрический ток. Риск поражения электрическим током вероятен при применении оборудования с неисправной проводкой или же изоляцией, неисправным состоянием розеток. Главные меры электробезопасности связаны с соблюдением правил применения электро-устройств, испытание исправности их проводки и изоляции, выключения устройств от электрической сети при покидании здания.</p>

Дата выдачи задания для раздела по линейному графику	15.03.2021
--	------------

Задание выдал консультант:

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Профессор	Белозеров В. Б.	Д.Г.-М.Н.		15.03.21г.

Задание принял к исполнению студент:

Группа	ФИО	Подпись	Дата
2ТМ91	Вальман Никита Константинович		15.03.21г.

Реферат

Выпускная квалификационная работа состоит из 106 страниц, 31 рисунок, 9 таблиц, и 60 источников использованной литературы.

Ключевые слова: SRM-6, нейронная сеть, граф, нефть, скважина, технологические параметры.

Объектом исследования является синтетическое месторождение SRM-6.

Предметом исследования являются методика прогнозирования технологических параметров работы скважин, посредством графовой нейронной сети.

Цель работы: использование теории графов с целью адаптации гидродинамической модели и расчета технологических показателей работы скважин с учетом возможности масштабирования указанной методики на верхнеюрские отложения.

В данной работе рассмотрены общие сведения о нейронных сетях и графах, проведен анализ исходной синтетической модели, создана методика и проведено ее опробование на объекте исследования.

Область применения: разработка нефтяных месторождений.

Экономическая значимость данной работы обусловлена возможностью сокращения затрат на процесс моделирования месторождений углеводородного сырья.

Перечень обозначений и сокращений

- ВНК — водонефтяной контакт;
- ГИС — геофизические исследование скважин;
- НЛП — нейролингвистическое программирование;
- ОФП — относительная фазовая проницаемость;
- ПК — персональный компьютер;
- BFS — breadth-first search или поиск в ширину;
- CNN — convolutional neural network или сверточная нейронная сеть;
- DFS — depth-first search или поиск в глубину;
- GAN — generative adversarial network или генеративно-сопоставительная нейросеть;
- GNN — graph neural network или графовая нейронная сеть;
- LSTM — long short-term memory или рекуррентные нейронные сети с долгой краткосрочной памятью;
- MSE — Mean Squared Error или средняя квадратичная ошибка;
- RNN — recurrent neural network или рекуррентная нейронная сеть;
- SNA — Systems Network Architecture или архитектура нейронной сети.

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	20
1 ГЕОЛОГИЧЕСКАЯ ХАРАКТЕРИСТИКА МОДЕЛИ SRM-6.....	22
1.1 Краткие сведения о месторождении	22
2 НЕЙРОННЫЕ СЕТИ И ИХ РАЗНОВИДНОСТИ	27
2.1 История нейронных сетей.....	27
2.2 Типы нейронных сетей.....	28
2.3 Механизм работы нейронных сетей.....	30
2.4 Графовые нейронные сети (GNN).....	33
2.4.1 Теория графов.....	33
2.4.2 Сложность анализа графов.....	34
2.4.3 Преимущества графового представления данных.....	35
2.4.4 Традиционные методы анализа графов	36
2.4.5 Графовая нейронная сеть	36
2.4.6 Рекуррентная графовая нейронная сеть	37
2.4.7 Пространственная сверточная сеть	39
2.4.8 Спектральная сверточная сеть.....	39
2.4.9 Функции GNN	42
2.4.10 Некоторые реальные применения	43
3 ПРИМЕНЕНИЕ ТЕОРИИ ГРАФОВ ПРИ РАСЧЕТЕ ТЕХНОЛОГИЧЕСКИХ ХАРАКТЕРИСТИК РАБОТЫ СКВАЖИН	47
3.1 Дальнейшие планы развития	53
4 ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ.....	59
5 СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ.....	64
5.1 Нормативная база.....	64
5.2 Трудовой кодекс.....	64
5.3 Вредоносные факторы.....	65
5.4 Гигиенические требования.....	65
5.5 Инструктаж по технике безопасности за компьютером	66
5.6 Меры безопасности перед началом работы	67

5.7 Техника безопасности возле компьютера в процессе работы.....	67
5.8 Рекомендованное положение тела при сидячей работе.....	68
5.8.1 Положение ног при работе за компьютером.....	68
5.8.2 Положение спины и шеи при работе на ПК.....	69
5.8.3 Усталость глаз от компьютера	71
5.8.4 Правильное положение рук	71
5.8.5 Правильная настройка стола при работе за компьютером.....	73
5.8.6 Дыхание во время работы за компьютером	75
5.8.7 Условия работы за компьютером (температура, влажность, освещенность)	76
5.9 Режимы труда и отдыха.....	77
ЗАКЛЮЧЕНИЕ	80
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ	82
Приложение А	88

ВВЕДЕНИЕ

Актуальность работы заключается в разработке новой методики прогноза технологических показателей скважин при помощи графовой нейронной сети, что является одним из новейших типов нейронных сетей.

Существуют разные виды нейронных сетей: рекуррентная, сверточная, графовая. Последний вид начал развиваться в 2018 году. В основном разработками на его основе занимаются за рубежом. Уникальность графового представления нейронной сети заключается в визуальном представлении графа и затем его кодировании в воспринимаемый алгоритмом обработки вид.

Графы – это структура данных, которая представляет собой набор объектов (узлов) и их отношений (ребер). В последнее время исследованиям по анализу графов с помощью машинного обучения уделяется все больше внимания из-за большой выразительной силы графов, графы могут использоваться в качестве обозначения большого числа систем в различных областях. Графы являются уникальной неевклидовой структурой данных, в алгоритмах машинного обучения их анализ фокусируется на таких задачах, как классификация узлов, прогнозирование связей и кластеризация. Графовые нейронные сети (GNN) – это методы, основанные на глубоком обучении, в основе которых лежит математический аппарат осуществляющий обработку и анализ данных, представленных в виде графовой структуры. В последние годы варианты GNN, такие как сверточная сеть на графах (GCN), сеть внимания на графах (GAT), повторяющаяся сеть на графах (GRN), продемонстрировали новаторскую производительность во многих задачах глубокого обучения.

Теоретические вопросы разработки нейронных сетей иллюстрируются в работах: Jie Zhou (2019), Ganqu Cui (2017), Shengding Hu (2018), Zhengyan

Zhang (2016), Cheng Yang (2018), Zhiyuan Liu (2018), Lifeng Wang (2020) [43, 14, 9, 38, 54, 44, 55].

Объектом исследования является синтетическое месторождение SRM-6.

Предметом исследования является методика прогнозирования технологических параметров работы скважин, с использованием графовой нейронной сети.

Цель работы: использование теории графов с целью адаптации гидродинамической модели и расчета технологических показателей работы скважин с учетом возможности масштабирования указанной методики на верхнеюрские отложения.

Применение разработанного механизма предполагается на синтетической модели резервуара SRM-6, состоящей из 6 скважин (3 нагнетательных, 3 добывающих). Мощность целевого интервала варьируется от 11 до 14 метров.

Задачи исследования:

- Изучить язык программирования «Python» на базовом уровне;
- Ознакомиться с разновидностями нейронных сетей, изучить основы работы с графовыми нейронными сетями;
- Применить графовые нейронные сети с целью адаптации гидродинамической модели SRM-6 и расчета технологических показателей работы скважин;

Теоретическая основа разрабатываемой методики была представлена на XXV Международном научном симпозиуме студентов и молодых ученых имени академика М.А. Усова «Проблемы геологии и освоения недр» в виде статьи «Применение теории графов при расчёте технологических характеристик работы скважин на примере синтетического месторождения SRM-6».

1 ГЕОЛОГИЧЕСКАЯ ХАРАКТЕРИСТИКА МОДЕЛИ SRM-6

1.1 Краткие сведения о месторождении

SRM-6 — синтетическая модель коллектора [60] (Рисунок 1.1), являющаяся примером верхневасюганской подсветы и расположенного в ней горизонта Ю-1.




Рисунок 1.1 — Общий вид геологической модели SRM-6 [60].

Синтетическую модель SRM-6, взятую для опробования методики, заявленной в теме магистерской диссертации, создал Еремян Грачик Араикович путем усреднения геофизических исследований скважин (ГИС), пористости, проницаемости, а также графиков относительных фазовых проницаемостей (ОФП) и результатов исследования капиллярного давления по одному из месторождений Западной Сибири.

SRM-6 содержит в себе 6 скважин (3 нагнетательных, 3 добывающих) и является численной моделью, которая содержит 6 480 ячеек (размерность сетки 18 x 24 x 15). Площадь моделируемого участка составляет 1800 x 2400 метров, а толщина целевого слоя колеблется от 11 до 14 метров [60].

Рисунки 1.2 - 1.4 иллюстрируют распространение средних свойств модели.




Рисунок 1.2 — Карта средней пористости

Согласно Рисунку 1.2 тренд увеличения пористости направлен с севера на юг.




Рисунок 1.3 — Карта средней проницаемости

Тренд распространения проницаемости наследуется от пористости. Сравнивая карту пористости (Рисунок 1.2) и карту проницаемости (Рисунок

1.3) зоны увеличения и уменьшения коррелируют в большей части зон на данных картах.

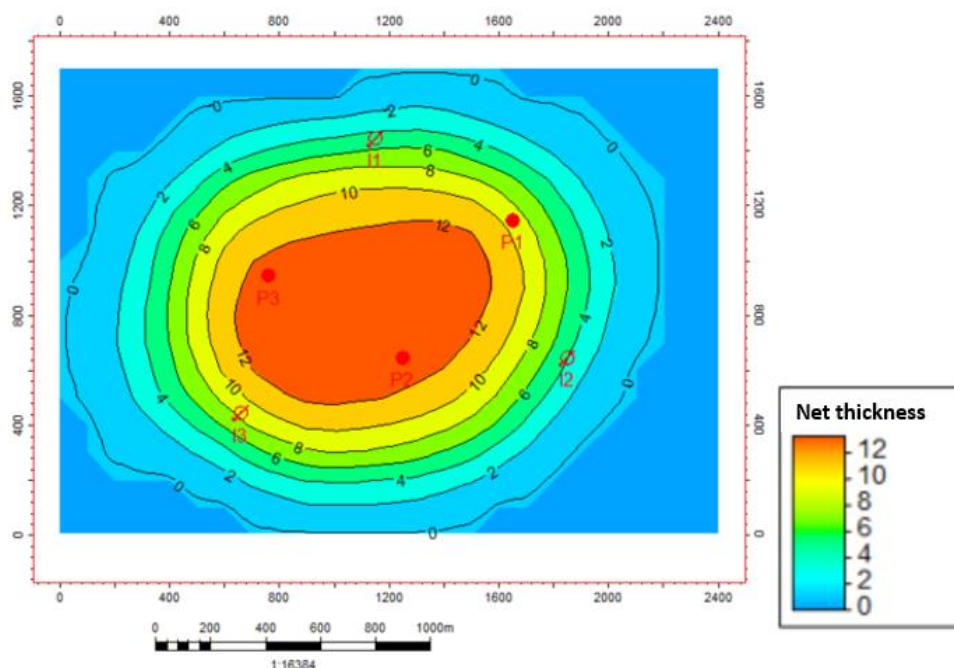


Рисунок 1.4 — Карта нефтенасыщенных тощин

Залежь имеет пластово-сводовую структуру. Средняя начальная водонасыщенность в нефтяной части залежи — 0,4.

Геологические запасы нефти участка составляют 600 тыс м³, а подвижные запасы составляют 210 тыс м³.

В модели представлена избирательная сетка скважин, т.к. данное расположение скважин невозможно отнести ни к одному из стандартных расположений скважин. Нагнетательные скважины расположены в законтурной зоне.

Гистограммы распределения петрофизических свойств показаны на Рисунке 1.5. Среднее значение пористости — 0,18. Среднее значение проницаемости — 45,2 мД.




Рисунок 1.5 — Гистограммы распределения: а— пористости,
б — проницаемости [60]

Исходная гидродинамическая модель не была адаптирована на исторические данные по работе скважин. В процессе выполнения работы дополнительно была проведена ее адаптация путем локальной корректировки петрофизических свойств и относительных фазовых проницаемостей.

На рисунке 1.7 показаны характеристики работы скважин в модели (дебиты нефти, воды, жидкости, а также забойное давление) и результат адаптации на исторические данные.

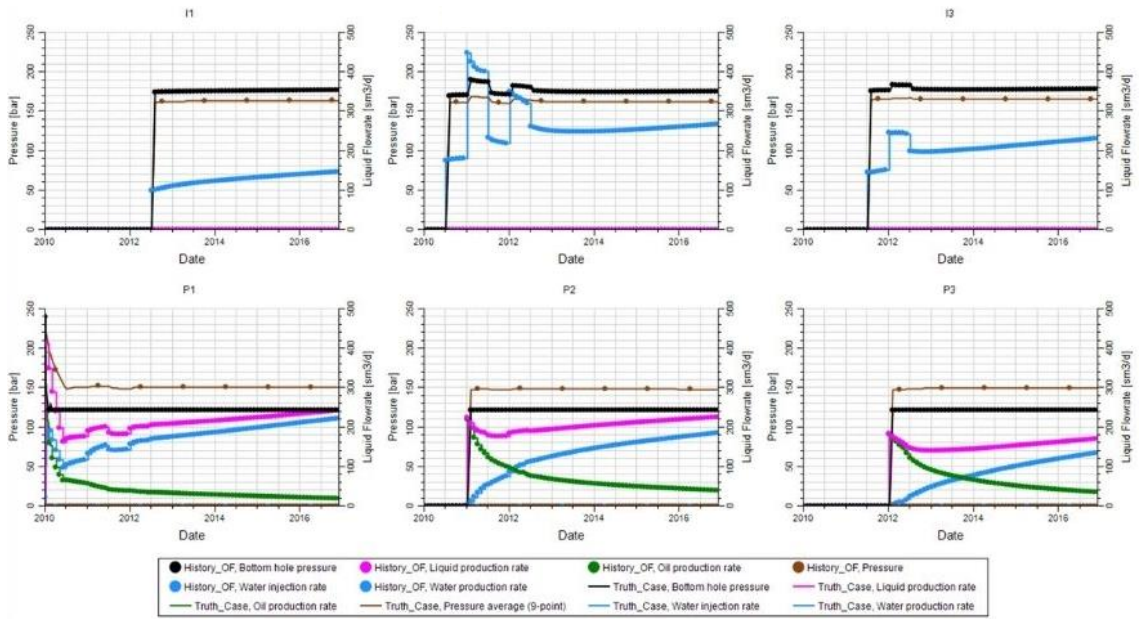


Рисунок 1.7 — Модель после адаптации [60]

2 НЕЙРОННЫЕ СЕТИ И ИХ РАЗНОВИДНОСТИ

Нейронные сети - это вычислительные системы со взаимосвязанными узлами, которые работают так же, как нейроны в человеческом мозгу. Используя алгоритмы, они могут распознавать скрытые закономерности и корреляции в необработанных данных, кластеризовать и классифицировать их. Пример простейшей нейронной сети показан на Рисунке 2.1.




Рисунок 2.1 — Пример нейронной сети

2.1 История нейронных сетей

Идея «машины, которая думает самостоятельно» восходит к древним грекам, но исследования, результатом которых стала разработка нейронных сетей, начались в XX веке.

В 1943 году Уоррен С. Маккалок и Уолтер Питтс опубликовали статью «Логический расчет идей, присущих нервной деятельности». Предметом исследования стали процессы, осуществляемые человеческим мозгом при создании сложных моделей через связанные клетки мозга или нейроны.

Одной из основных идей, которые возникли в результате этой работы, было сравнение нейронов с бинарным порогом с булевой логикой (то есть, 0/1 или утверждения истинно / ложно) [25].

В 1958 году Фрэнк Розенблатт ввел понятие перцептрон или перцептрон – модели восприятия информации мозгом, математической или компьютерной. В исследовании «Перцептрон: вероятностная модель хранения и организации информации в мозге» в уравнения, описывающие процессы в человеческом мозге вводятся веса для переменных. Практический результат работы: Розенблатт научил машину (IBM 704) отличать карты, отмеченные слева, от карт, отмеченных справа [25].

Пол Вербос в 1974 году впервые исследует идею обратного распространения ошибки, и ее применение в нейронных сетях [25]. Эту идею развивает Ян Лекун. В 1989 году он опубликовал статью об алгоритмах, где показано, как использование ограничений в обратном распространении ошибки и его интеграция в архитектуру нейронной сети может использоваться для обучения алгоритмов. В этом исследовании успешно использовалась нейронная сеть для распознавания рукописных цифр почтового индекса, предоставленного почтовой службой США [25].

2.2 Типы нейронных сетей

Охарактеризуем преимущества и недостатки глубоких нейронных сетей, в зависимости от цели использования.

Сверточные нейронные сети (CNN) применяются при классификации изображений и обнаружении объектов. Они содержат пять типов слоев или уровней: вход, свертка, объединение, полносвязный и выходной слой. Каждый уровень имеет определенную цель, например, обобщение,

соединение или активацию. CNN также применяются при обработке естественного языка и прогнозировании.

Рекуррентные нейронные сети (RNN) используют последовательную информацию, такую как данные с отметками времени от сенсорного устройства или устное предложение, состоящее из последовательности терминов. В отличие от традиционных нейронных сетей, все входы в рекуррентную нейронную сеть не независимы друг от друга, а выходные данные для каждого элемента зависят от вычислений его предшествующих элементов. RNN используются в приложениях прогнозирования и временных рядов, анализе тональности и других текстовых приложениях [19].

Нейронные сети с прямой связью (FFN). Нейронные сети, в которых каждый перцептрон в одном слое подключен к каждому перцептрону из следующего слоя. Информация передается от одного уровня к другому только в прямом направлении. Нет никаких петель обратной связи. Нейронные сети с прямой связью используются в задачах прогнозирования, для распознавания образов и в задачах управления.

Нейронные сети с автоэнкодерами (AEN). Идея автоэнкодеров состоит в том, чтобы снизить чувствительность несущественного и повысить чувствительность релевантного. Нейронные сети с автоэнкодерами используются для создания абстракций (кодировщиков), созданных из заданного набора входных данных. Автоэнкодеры похожи на традиционные нейронные сети, но они стремятся моделировать сами входные данные, и поэтому метод считается неконтролируемым. По мере добавления слоев дальнейшие абстракции формулируются на более высоких уровнях (уровнях, ближайших к точке, в которой вводится уровень декодера). Эти абстракции затем могут использоваться линейными или нелинейными классификаторами [54].

2.3 Механизм работы нейронных сетей

Каждый отдельный узел нейронной сети – индивидуальная линейная регрессионная модель, состоящая из входных данных, весов, смещения и выходных данных [49]. После определения входного слоя назначаются веса. Эти веса помогают определить важность любой данной переменной, причем более крупные из них вносят более значительный вклад в результат по сравнению с другими входными данными. Затем все входные данные умножаются на их соответствующие веса и затем суммируются. Формула будет выглядеть примерно так:

$$\sum w_i x_i + \text{bias} = w_1 x_1 + w_2 x_2 + w_3 x_3 + \text{bias} \quad (2.1)$$

$$\text{output} = f(x) = 1, \text{ если } \sum w_i x_i + b \geq 0; 0, \text{ если } \sum w_i x_i + b < 0 \quad (2.2)$$

После этого вывод проходит через функцию активации, которая определяет вывод. Если этот выходной сигнал превышает заданный порог, он «запускает» (или активирует) узел, передавая данные на следующий уровень в сети [38]. Это приводит к тому, что выход одного узла становится входом следующего узла. Этот процесс передачи данных от одного уровня к следующему определяет эту нейронную сеть как сеть прямого распространения.

Рассмотрим пример единственного узла, используя двоичные значения. Вопрос: стоит ли заниматься серфингом (Да: 1, Нет: 0) [58]. Решение идти или не идти - это прогнозируемый результат. Предположим, на решение влияют три фактора:

1. Хорошие ли волны? (Да: 1, Нет: 0)
2. Свободно ли море? (Да: 1, Нет: 0)
3. Было ли нападение акулы в последнее время? (Да: 0, Нет: 1)

Зададим следующие входные данные:

- $X_1 = 1$, так как волны раскачивают
- $X_2 = 0$, поскольку толпы нет

- $X_3 = 1$, поскольку в последнее время не было нападения акул.

Следующий шаг – присвоение переменным весов, чтобы определить важность. Большие веса означают, что определенные переменные имеют большее значение для решения или результата.

- $W_1 = 5$, так как большие порывы ветра возникают нечасто
- $W_2 = 2$, так как вы привыкли к толпе
- $W_3 = 4$, так как вы боитесь акул

Наконец, пороговое значение 3, что соответствует значению смещения -3 . Подставляя входные данные в формулу (1), получаем:

$$\hat{y} = (1 * 5) + (0 * 2) + (1 * 4) - 3 = 6 \quad (2.3)$$

Если воспользоваться функцией активации (2.2), станет возможным определить, что на выходе этого узла будет 1, поскольку 6 больше 0. В этом случае человек будет заниматься серфингом; но, если будут скорректированы веса или порог, в модели могут быть получены другие результаты и другое значение на выходе такого узла [16]. Наблюдая за одним решением, как в приведенном выше примере, можно увидеть, как нейронная сеть может принимать все более сложные решения в зависимости от результатов предыдущих решений или уровней.

В приведенном выше примере были использованы перцептроны, чтобы проиллюстрировать некоторые математические аспекты получения значений на выходе из узла. Нейронные сети, как правило, используют сигмовидные нейроны, которые различаются интервалом значений от 0 до 1. Нейронные сети ведут себя аналогично деревьям решений, данные каскадно передаются от одного узла к другому. Наличие значений x между 0 и 1 уменьшает влияние любого заданного изменения одной переменной на вывод любого заданного узла, а затем и на вывод нейронной сети [6].

При практических вариантах использования нейронных сетей, таких как распознавание или классификация изображений, используется контролируемое обучение или размеченные наборы данных для обучения алгоритма. Во время обучения модели нужно будет оценить ее точность,

используя функцию стоимости (или потерь). Это также обычно называют среднеквадратичной ошибкой (MSE).

$$\text{Cost Function} = \text{MSE} = 1/2m \sum (\hat{y} - y)^2 \quad (2.4)$$

где

- i — индекс образца,
- \hat{y} — прогнозируемый результат,
- y — фактическое значение,
- m — количество образцов.

В конечном итоге цель состоит в том, чтобы минимизировать функцию затрат, чтобы гарантировать правильность отладки/обучения алгоритма для любого данного наблюдения. По мере того, как модель корректирует свои веса и смещение, она использует функцию стоимости и обучение с подкреплением, чтобы достичь точки сходимости или локального минимума [29]. Процесс, в котором алгоритм корректирует свои веса, осуществляется посредством градиентного спуска, что позволяет модели определять направление, в котором следует двигаться, чтобы уменьшить ошибки (или минимизировать функцию стоимости). В каждом примере обучения параметры модели настраиваются так, чтобы постепенно сходиться к минимуму.




Рисунок 2.2— Пример показывающий взаимосвязь потерь и значений весов между значениями

Большинство глубоких нейронных сетей имеют прямую связь, то есть они движутся только в одном направлении, от входа к выходу. Однако можно обучить модель с помощью обратного распространения ошибки; то есть двигаться в противоположном направлении от вывода к вводу. Обратное распространение позволяет вычислить и приписать ошибку, связанную с каждым нейроном, что позволяет соответствующим образом настроить и подогнать параметры модели (моделей) [22].

2.4 Графовые нейронные сети (GNN)

2.4.1 Теория графов

Граф – структура данных, состоящая из двух компонентов: вершин и ребер. Он используется как математическая структура для анализа парных или бинарных отношений между объектами и сущностями [48]. Обычно граф, показанный на Рисунке 2.3, определяется как $G = (V, E)$, где V – это набор узлов, а E – ребра между ними.




Рисунок 2.3 — Простой граф [8].

Граф часто представлен матрицей смежности A . Если граф имеет N узлов, то A имеет размерность $(N \times N)$. Иногда предоставляется матрица признаков для описания узлов на графе. Если каждый узел имеет F номеров функций, тогда матрица признаков X имеет размер $(N \times F)$.

2.4.2 Сложность анализа графов

Для произвольного графа, как правило, нельзя построить модель в трехмерном евклидовом пространстве. Это значительно усложняет интерпретацию данных графа по сравнению с другими типами данных, такими как волны, изображения или сигналы временных рядов («текст» также можно рассматривать как временные ряды), которые можно легко представить в двумерном (2-D) или трехмерном (3-D) евклидовом пространстве.

Во-вторых, граф не имеет фиксированной формы. Граф А (рис. 2.4) и граф Б (рис.2.5) имеют совершенно разную структуру и визуально различаются. Но при представлении каждого из этих графов матрицей смежности получим одинаковый результат (если не учитывать вес ребер).




Рисунок 2.4 — Граф А [8].




Рисунок 2.5 — Граф Б [8].

Рассмотренные графы А и Б нетрудно визуализировать для дальнейшей интерпретации. Если размерность графа велика, т.е. он включает сотни или тысячи узлов, и узлы плотно сгруппированы, то это сильно затрудняет понимание графа, его визуализацию. Поэтому обучить машину этой задаче сложно. На рисунке 2.6 показан граф, моделирующий логические вентили в интегральной схеме [52].




Рисунок 2.6 — Пример гигантского графа [26].

2.4.3 Преимущества графового представления данных

Перечислим причины, по которым отдается предпочтение работе с графами:

1. Графы обеспечивают лучший способ работы с абстрактными понятиями, такими как отношения и взаимодействия. Они также предлагают интуитивно-визуальный способ осмысления этих концепций. Графы также составляют естественную основу для анализа отношений в социальном контексте [41].

2. Графы могут решать более сложные проблемы, упрощая проблемы до более простых представлений или преобразовывая проблемы в представления с разных точек зрения [41].

3. Теории и концепции графов используются для изучения и моделирования социальных сетей, моделей мошенничества, моделей энергопотребления, вирусности и влияния в социальных сетях. Анализ социальных сетей (SNA), вероятно, самое известное приложение теории графов для науки о данных [41].

2.4.4 Традиционные методы анализа графов

Традиционные методы анализа графов основаны на следующих алгоритмах:

1. алгоритмы поиска, например, BFS, DFS
2. алгоритмы кратчайшего пути, например, алгоритм Дейкстры (ближайшего соседа)
3. алгоритмы связующего дерева, например, алгоритм Прима
4. методы кластеризации, например, высокосвязные компоненты, k-среднее [24]

Ограничение таких алгоритмов состоит в том, что необходимо получить предварительные знания о графе с определенной степенью уверенности, прежде чем получится применить алгоритм. Другими словами, это не дает возможности изучить сам граф. И самое главное, нет возможности выполнить классификацию на уровне графа [28].

2.4.5 Графовая нейронная сеть

Графовая нейронная сеть – это нейронная сеть, которую можно использовать в случае, когда исходные данные представлены в виде графа.

Такая сеть используется для задач прогнозирования на уровне узла, уровне края и уровне графа [36].

В литературе представлены в основном три типа графовых нейронных сетей:

1. Рекуррентная графовая нейронная сеть
2. Пространственная сверточная сеть
3. Спектральная сверточная сеть

Интуиция графовой нейронной сети в том, что узлы естественным образом определяются своими соседями и соединениями. Следовательно, соседи узла и соединения с соседями определяют концепцию узла [27]. Поэтому в нейронных графовых сетях каждому узлу задается состояние (x), чтобы представить его концепцию. Можно использовать состояние узла (x) для получения вывода (o), то есть решения о концепции [39]. Конечное состояние (x_n) узла обычно называется «внедрением узла». Задача всей GNN - определить «вложение узла» для каждого узла, просматривая информацию о его соседних узлах.

2.4.6 Рекуррентная графовая нейронная сеть

Рекуррентная нейронная сеть построена на основе теоремы Банаха о неподвижной точке. Теорема Банаха о неподвижной точке утверждает, что: Пусть (X, d) - полное метрическое пространство и пусть $(T: X \rightarrow X)$ – сжимающее отображение [45]. Тогда T имеет единственную неподвижную точку (x^*) и для любого $x \in X$ последовательность $T_n(x)$ при $n \rightarrow \infty$ сходится к (x^*). Это означает, что если применить к x отображение T k раз, x^k должно быть приблизительно равно $x^{(k-1)}$, то есть:

$$X_k = T(x^{k-1}), k \in (1, n) \quad (2.5)$$

Рекуррентная нейронная сеть определяет параметризованную функцию f_w :

$$x_n = f_w(l_n, l_{co[n]}, x_{ne[n]}, l_{ne[n]}) \quad (2.6)$$

где l_n , l_{co} , x_{ne} , l_{ne} представляют характеристики текущего узла $[n]$, края узла $[n]$, состояние соседних узлов и характеристики соседних узлов [44].




Рисунок 2.7 — Иллюстрация обновления состояния узла на основе информации о его соседях [11].

Наконец, после k итераций конечное состояние узла используется для создания выходных данных для принятия решения по каждому узлу (Рисунок 2.7). Функция вывода определяется как:

$$O_n = g_w(x_n, l_n) \quad (2.7)$$

2.4.7 Пространственная сверточная сеть

Интуиция сети пространственной свертки аналогична интуиции сети CNN, которая наиболее часто используется при решении задач классификации и сегментации изображений [32].

Идея свертки изображения заключается в суммировании соседних пикселей вокруг центрального пикселя, заданного фильтром с параметризованным размером и обучаемым весом [35]. Пространственная сверточная сеть использует ту же идею, объединяя функции соседних узлов в центральный узел.




Рисунок 2.8 — Свертка графов (Слева: свертка на обычном графе, таком как изображение. Справа: свертка произвольной структуры графа) [23].

2.4.8 Спектральная сверточная сеть

Спектральная сверточная сеть построена на основе теории обработки сигналов графа, путем упрощения и приближения свертки графа [7].

На основе полиномиального приближения Чебышева, свертку графа можно упростить до следующего вида:

$$g_{\theta} * x \approx \sum_{k=0}^K \theta_k T_k(\Delta) \quad (2.8)$$

После дальнейшего упрощения GCN предлагает двухуровневую структуру нейронной сети, которую можно описать одним уравнением:

$$Z=f(X,A)=\text{softmax}(\hat{A} \text{Relu}(\hat{A} XW^{(0)})W^{(1)}) \quad (2.9)$$

где \hat{A} - это предварительно обработанный лапласиан исходной матрицы смежности графа A [20].

Данная формула – это обычно используемая двухуровневая структура, но в этом случае она служит сверткой графа.




Рисунок 2.9 — Пример графа с характеристикой, назначенной каждому узлу [53].

Предположим, у нас есть простой граф с 4 узлами. Каждому из этих узлов назначается матрица признаков, как показано на Рисунке 2.9. Легко получить матрицу смежности графа и матрицу функций, как показано ниже [34]:

1	1	1	0
1	1	1	0
1	1	1	1
0	0	1	1

Adjacency matrix (A)

1	0	0
0	1	0
0	0	1
0	1	1

Feature matrix (X)

Рисунок 2.10 — Пример матрицы смежности и матрицы признаков [40].

Диагональ матрицы смежности намеренно изменена на «1», чтобы добавить петлю для каждого узла [9]. Это должно включать функцию каждого узла, когда выполняем агрегирование функций.

$$A \times X = H$$

1	1	1	0	×	1	0	0	=	1	1	1	
1	1	1	0		0	1	0		1	1	1	1
1	1	1	1		0	0	1		1	1	2	2
0	0	1	1		0	1	1		2	1	2	

$$h_{1,1} = A_{1,1}X_{1,1} + A_{1,2}X_{2,1} + A_{1,3}X_{3,1} + A_{1,4}X_{4,1}$$

$$h_{1,2} = A_{1,1}X_{1,2} + A_{1,2}X_{2,2} + A_{1,3}X_{3,2} + A_{1,4}X_{4,2}$$

$$h_{1,3} = A_{1,1}X_{1,3} + A_{1,2}X_{2,3} + A_{1,3}X_{3,3} + A_{1,4}X_{4,3}$$

Рисунок 2.11 — Пример свертки графа умножением матриц [46].

Результат умножения матриц показан в самой правой матрице. Рассмотрим на примере приведенную особенность первого узла. Нетрудно заметить, что результат представляет собой сумму всех характеристик узла 1, включая функцию самого узла 1, а функции узла 4 не включаются, поскольку он не является соседом узла 1 [15]. Математически матрица смежности графа имеет значение «1» только при наличии ребра и «0» в противном случае. Это делает матричное умножение суммой характеристик узлов, которые подключены к опорному узлу.

Следовательно, спектральная сверточная сеть и пространственная сверточная сеть, имея различные основания, используют одно и то же правило распространения [47].

Все доступные в настоящее время нейронные сети сверточных графов используют один и тот же формат. Все они пытаются изучить функцию для

передачи информации об узле и обновления состояния узла с помощью этого процесса передачи сообщений [59].

Любая графовая нейронная сеть может быть выражена как нейронная сеть (J. Gilmer et al., 2017) с функцией передачи сообщений M_t , функцией обновления узла H^{l+1} и функцией считывания y .

$$m^{l+1}=M_t(H^l,A) \quad (2.10)$$

$$H^{l+1}=U_t(H^l,m^{l+1}) \quad (2.11)$$

$$y=R(H^l) \quad (2.12)$$

2.4.9 Функции GNN

Проблемы, которые решает GNN, можно условно разделить на три категории [17]:

1. Классификация узлов
2. Прогнозирование ссылок
3. Классификация графов

При классификации узлов задача состоит в том, чтобы предсказать внедрение узла для каждого узла в графе. Этот тип задач обычно обучается полу-контролируемым способом, когда помечена только часть графа [31]. Типичные приложения для классификации узлов включают сети цитирования, сообщения Reddit, видео на Youtube и отношения с друзьями в Facebook.

При прогнозировании связи задача состоит в том, чтобы понять взаимосвязь между объектами в графах и предсказать, есть ли между двумя объектами связь. Например, рекомендательную систему можно рассматривать как проблему прогнозирования ссылок, где модели дается набор пользовательских обзоров различных продуктов, задача состоит в том, чтобы предсказать предпочтения пользователей и настроить рекомендательную систему для продвижения более релевантных продуктов [42].

При классификации графов задача состоит в том, чтобы классифицировать весь граф по различным категориям. Это похоже на классификацию изображений, но цель меняется на область графа. Существует широкий спектр промышленных задач, в которых классификация графов может применяться, например, в химии, биомедицине, физике, где модели задается молекулярная структура и предлагается классифицировать цель по значимым категориям [56]. Это ускоряет анализ атома, молекулы или любых других типов структурированных данных.

2.4.10 Некоторые реальные применения

GNN в обработке естественного языка.

GNN широко используется в обработке естественного языка (NLP). Как правило, человек думает, что текст должен быть типом последовательных или временных данных, которые лучше всего описываются RNN или LTSM [14]. GNN подходит к проблеме с совершенно другой точки зрения. GNN использует внутренние отношения слов или документов для предсказания категорий. Например, сеть цитирования пытается предсказать этикетку каждой статьи в сети, задаваемую соотношением цитирования статьи и словами, которые цитируются в других статьях. Он также может построить синтаксическую модель, рассматривая разные части предложения вместо чисто последовательных, как в RNN или LTSM.

GNN в компьютерном зрении (CV).

Многие методы, основанные на CNN, позволяют с высокой точностью обнаружить объект на изображениях, но все же не дают точного знания о взаимоотношениях между объектами. Одно из успешных применений GNN в CV – использование графов для моделирования отношений между объектами, обнаруженными детектором на основе CNN [33]. После того, как объекты

обнаружены на изображениях, они затем передаются в GNN-вывод для предсказания взаимосвязи, как показано на Рисунке 2.12. Результатом вывода GNN является сгенерированный граф, моделирующий отношения между различными объектами.

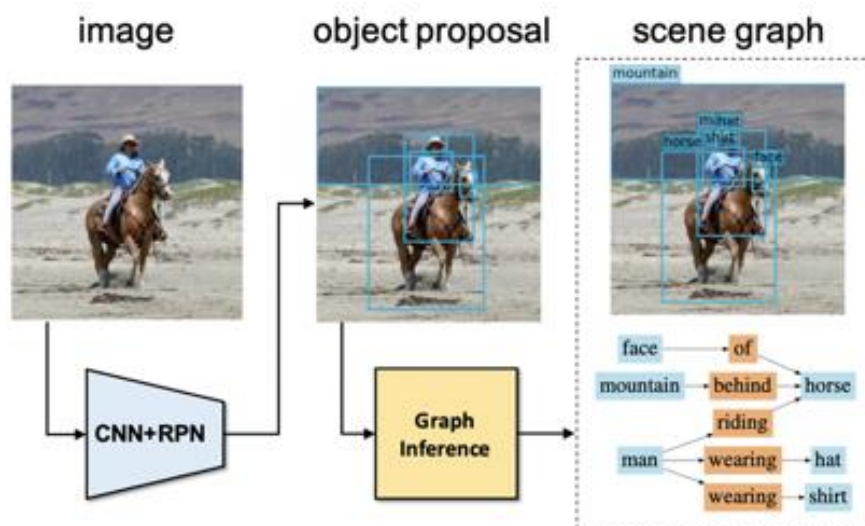


Рисунок 2.12 — Создание графа сцены [55].

В CV существует возможность создания изображений из описаний графов. Традиционный способ генерации изображений - это генерация текста в изображение с использованием GAN или автокодировщика [57]. В CV вместо использования текста для описания изображения, создается граф для изображения. Он предоставляет больше информации о семантических структурах изображений (Рисунок 2.13).




Рисунок 2.13 — Изображение сгенерировано из графов сцены [13].

Обучение с нулевым выстрелом

Обучение с нулевым выстрелом (ZSL). ZSL пытается научиться классифицировать класс, не учитывая обучающих выборок (целевых классов). Это трудоемкая задача, потому что, если не было дано обучающих выборок, нужно позволить модели «думать» логически, чтобы распознать цель. Например, если даны три изображения (как показано на Рисунке 2.14) и нужно найти среди них «окапи». Возможно, человек раньше не видел «окапи» [51]. Но если бы ему также была предоставлена информация о том, что «окапи» – это животное с оленьим лицом, четырьмя ногами и полосатой кожей, то нетрудно выяснить, какое из представленных животных «окапи». Типичные методы – моделирование этого «мыслительного процесса» путем преобразования обнаруженных признаков в текст. Однако кодировки текста независимы друг от друга. Сложно смоделировать отношения между текстовыми описаниями.



Can you find “okapi” in these images?

Рисунок 2.14 — Распознавание нулевого выстрела через семантические вложения и графы знаний [18].

GNN в других доменах

Более практические применения GNN включают обнаружение человеческого поведения, управление трафиком, исследование молекулярной структуры, рекомендательную систему, проверку программ, логическое рассуждение, прогнозирование социального влияния и предотвращение враждебных атак [43]. Ниже показан граф, моделирующий отношения людей

в социальной сети. GNN можно применять для объединения людей в различные группы сообщества.

3 ПРИМЕНЕНИЕ ТЕОРИИ ГРАФОВ ПРИ РАСЧЕТЕ ТЕХНОЛОГИЧЕСКИХ ХАРАКТЕРИСТИК РАБОТЫ СКВАЖИН

Чтобы представить данные гидродинамической модели в удобном для «Python» и «PyTorch Geometric» виде использовалась модель графа.

При формировании кластера данных, которые в последствие использовались для написания кода, требовалось обозначить каждую скважину и их соединения новым индексом/номером (Рисунок 3.1-3.2). Скважины рассматриваемого участка месторождения представлялись в виде узлов пронумерованного графа. Ребра графа характеризовали взаимосвязи между скважинами, определенные из предположения, что каждая из скважин влияет на параметры работы ближайших к ней.

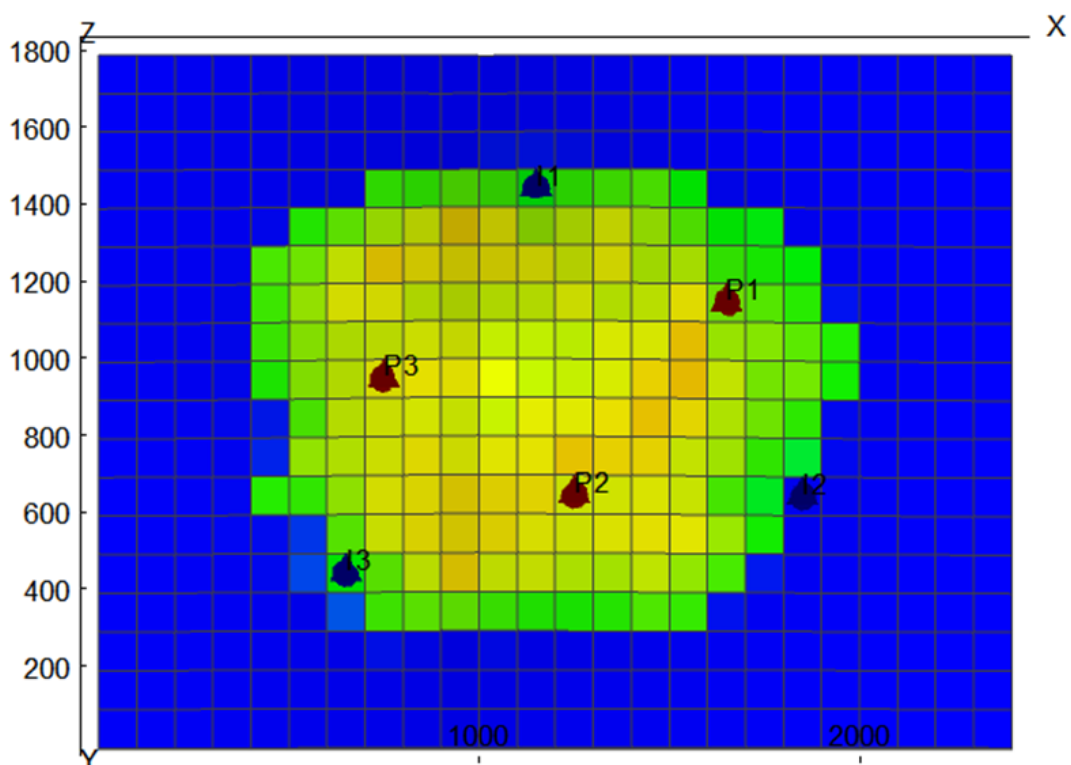


Рисунок 3.1 — Модель до пере-обозначения.

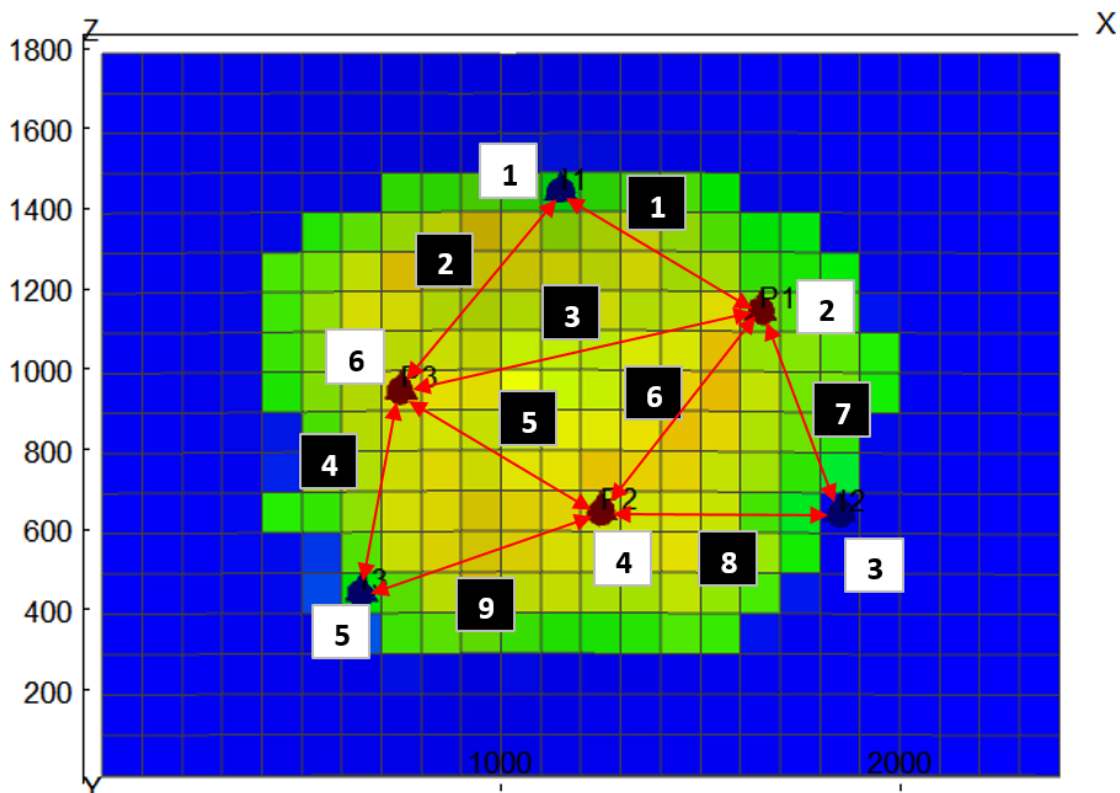


Рисунок 3.2 — Модель после пере-обозначения (в черных квадратах номера связей между скважинами, в белых квадратах номера скважин).

Следующим этапом построения нейронной сети было создание массива данных, характеризующие свойства коллектора вблизи каждой из скважин и режимы их работы. Он создавался по средствам анализа исходных данных по SRM-6. В основе теоретической базы методики и логики построения графа лежат работы по предсказанию дорожного трафика [9,32].

Массив данных состоит из данных для обучения нейронной сети — 5 статических параметров (Таблица 3.1) и 1 динамический – дебиты по каждой из скважин. Статические не меняются в процессе расчета сети, а динамический меняется и является рядом данных, на основе которых можно в конце сделать заключение о точности нейронной сети.

Таблица 3.1 — Статические параметры по шести скважинам

	P1	P2	P3	I1	I2	I3
x	17	13	8	12	19	7
y	7	12	9	4	12	14
Porosity	0,180	0,181	0,177	0,172	0,171	0,174
Permeability	54,16	58,82	44,03	38,63	35,11	39,40
Saturation	0,462	0,672	0,668	0,345	0,098	0,261

С целью получения корректно работающей нейронной сети, помимо данных для ее обучения, должен быть массив данных для проведения тестирования/сверки ее предсказательной способности (проверочная выборка).

В качестве обучающей выборки было взято первые шесть лет добычи из модели SRM-6, а качестве проверочной выборки — последний (седьмой) год добычи. Данные пределы обусловлены максимально возможным размером массива данных из имеющихся, которые могут послужить обучающей выборкой, а также обязательное наличие проверочной выборки, которая также должна быть достаточно репрезентативной.

Для первой реализации методики было взято минимально возможный размер массива данных, чтобы при успешном ее применении в дальнейшем усовершенствовать и можно было увеличить размер входного массива данных, тем самым продолжив тестирование и расширяя возможности нейронной сети.

Проверочной выборкой являлся последний год добычи в данном месторождении.

Во время реализации указанной методики в рамках магистерской диссертации не удалось довести до заявленной цели, поэтому была применена другая нейронная сеть, во основе которой не лежит графовое представление нейронных сетей, но она также выполняет функцию прогнозирования технологических параметров скважин.

Актуальность и привлекательность графовой нейронной сети остается неизменной, и в будущем данная методика будет доработана и осуществлена, а также планируется глубже рассмотреть физику пласта и реализовать методику, которая учитывает связь скважин каждой с каждой.

В реализованную нейронную сеть задается массив данных по добыче в течение шести лет, каждому нейрону устанавливается случайный вес, затем начинается обучение с методом обратного распространения ошибки. В случае если точность предсказания маленькая обратное распространение возвращается к 1 слою нейронной сети и меняет веса. Функция активации, которая говорит о том, какие нейроны начинают работать – сигмоида (Рисунок 3.3).




Рисунок 3.3 — Сигмоида или функция активации

Поскольку нейронная сеть по своему наполнению кода отличается от предполагаемой в заявленном методе, то количество эпох может достигать десятки тысяч. На выходе получаем предсказанные данные на основе тренировочного массива, который в последствии сравнивается с истинными значениями для определения точности предсказанных данных на проверочной выборке.

На Рисунке 3.4 отражена точность текущей нейронной сети на обучающей и тестовой выборках в процессе обучения, а на Рисунке 3.5

показаны значения дебитов, которые она прогнозирует на обучающей и тестовой выборках (данные зоны разделены красной вертикальной чертой).

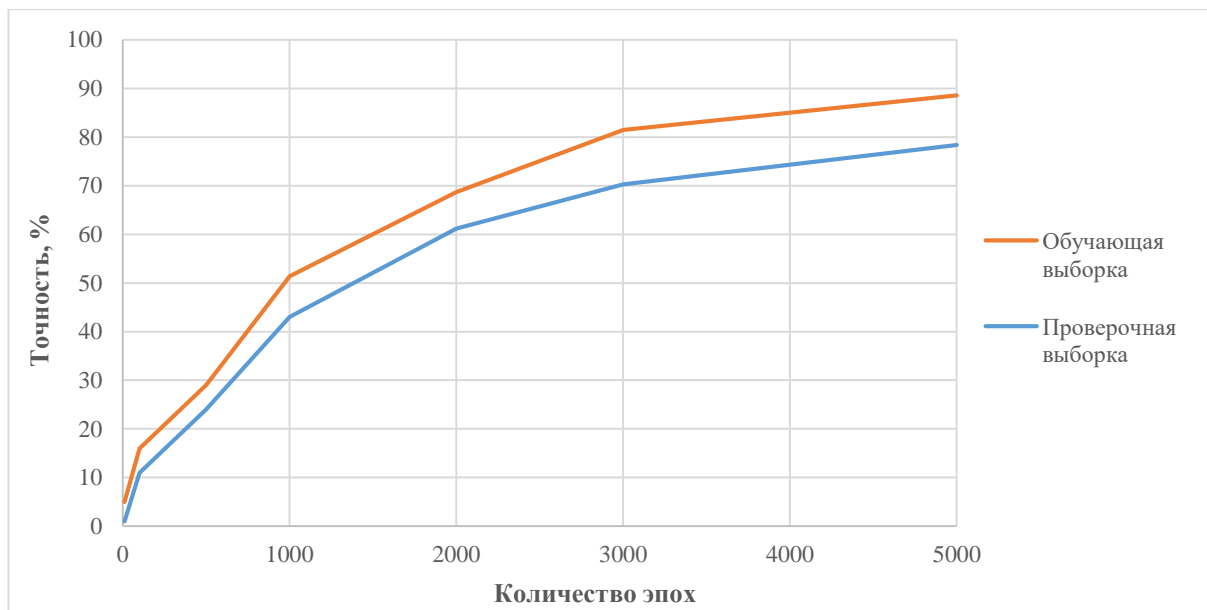


Рисунок 3.4 — Функция потерь процесса обучения и проверки.




Рисунок 3.5 — Сравнение показателей прогнозируемых дебитов и истинных показателей.

При подробном рассмотрении сравнительного Рисунка 3.5 можно заметить, что после первого снижения и резкого увеличения добычи, связанного с вводом новой скважины, дебит, который выдает нейронная сеть начинает больше отклоняться от истинных значений. Данное явление связано с попыткой нейронной сети уловить следующий ввод скважины и она думает, что каждое следующее значение может оказаться моментом ввода новой скважины.

Во время анализа данных было выявлено, что при исходном минимально возможном размере массива данных, данные полученные при значении эпох от 1 до 100 не репрезентативны, о чем говорит высокое значение погрешности.

Рассматривая результаты работы нейронной сети, для которой значение эпох равно 100 также сохраняется высокая погрешность, но уже значительно меньше. Чтобы определить удобимое число эпох раз за разом были увеличены значения. Как результат было достигнуто оптимальное значение в 5000 эпох, погрешность при которой равна 21 %.

Затем при увеличении числа эпох погрешность уменьшается, что является идеалом, но при таком значении время расчета увеличивается, если на используемом массиве данных это не так заметно, то при его увеличении время будет расти в геометрической прогрессии, практически, сразу достигнув критически высокого.

Из этого следует, что при дальнейшем расширении массива данных и применении методики на других массивах следует принять значение эпох равное 5000.

При большом количестве эпох может возникнуть проблема переобучения нейронной сети, когда результат чрезмерной подгонки параметров модели к зависимостям, содержащимся в обучающем множестве. Если происходит переобучение, то модель не приобретает способности к обобщению — возможности распространять обнаруженные на обучающем

множестве зависимости и закономерности на новые данные. Проблема переобучения является большим препятствием для малых массивов данных.

В нашем случае оптимальное число эпох не подвержено данному явлению, что подтверждается не слишком малым значением погрешности, а также видимые скачки при сравнении с истинными значениями, как обучающей выборки, так и проверочной.

3.1 Дальнейшие планы развития

В дальнейшем стоит глубже изучить физическую основу представления данных по работе скважин и свойствах коллектора в виде графа и применения к нему графовой нейронной сети, чтобы реализовать вначале указанный и описанный в работе подход, а затем перейти к усложнению методики и дополнить нейронную сеть способностью предсказать поведение существующих скважин и их влияние друг на друга при условии добавления новой скважины или изменения режима работы (ГТМ) существующей.

С целью более корректного и точного учета геологических особенностей и физических процессов, проходящих в пласте, следует учесть распределение свойств в межскважном пространстве.

Очевидно, что предположение об однородности свойств представляет собой очень упрощенный подход, который в некоторых случаях может считаться нефизичным, однако преимущества с точки зрения скорости и простоты анализа неоспоримы.

Полученная в результате модель должна удовлетворять требованиям:

1. учет всего имеющегося объема данных о пласте - геологию пласта, свойства флюидов, работу скважины;

2. возможность масштабирования на другие рассматриваемые месторождения.

Безусловно, подход с более полным представлением распределения свойств в пространстве между скважинами точнее с точки зрения физики пласта, но также потребует большего расчетного времени, но его увеличение будет незначительным, если использовать мощную вычислительную машину.

Исходя из всего выше сказанного, в виде входной информации в нейронную сеть будут подгружаться следующие данные:

- Распределение пористости по слоям между скважинами;
- Распределение проницаемости по слоям между скважинами;
- Распределение начальной воднасыщенности по слоям между скважинами, которая впоследствии будет пересчитана в нефтенасыщенность, как $S_o = 1 - S_w$.

Таблица 3.2 — Распределение пористости по слоям между скважинами
(по вертикали — слои модели, по горизонтали — связи модели).

Пористость, %									
слои/ связи	1	2	3	4	5	6	7	8	9
1	0,1474	0,1463	0,1439	0,1408	0,1474	0,1556	0,1556	0,1583	0,1521
2	0,1776	0,1664	0,1776	0,1708	0,1756	0,1874	0,1852	0,1772	0,171
3	0,201	0,204	0,2022	0,1888	0,1969	0,1974	0,1944	0,202	0,1946
4	0,1947	0,1966	0,1908	0,1854	0,197	0,1892	0,1866	0,1911	0,1954
5	0,185	0,1771	0,186	0,1939	0,1822	0,1816	0,1918	0,1873	0,1876
6	0,1789	0,1836	0,1827	0,1853	0,192	0,1838	0,184	0,1878	0,1926
7	0,1795	0,1861	0,1846	0,1827	0,1891	0,1901	0,1795	0,1795	0,1795
8	0,187	0,1846	0,1912	0,1737	0,1885	0,1875	0,1908	0,193	0,1836
9	0,1791	0,1782	0,189	0,1786	0,1817	0,1865	0,1888	0,1927	0,1815
10	0,178	0,1791	0,1751	0,1725	0,1737	0,1777	0,1743	0,1722	0,1783
11	0,171	0,1608	0,1786	0,1776	0,1806	0,189	0,1749	0,1695	0,1826
12	0,1683	0,18	0,1751	0,1833	0,1811	0,1704	0,1626	0,1738	0,1741
13	0,1642	0,1727	0,1698	0,1731	0,171	0,1637	0,1598	0,1502	0,1679
14	0,1723	0,1646	0,1632	0,1698	0,1681	0,1616	0,1566	0,1598	0,159
15	0,1525	0,1624	0,166	0,1669	0,1617	0,1627	0,1574	0,1572	0,1598

Таблица 3.3 — Распределение проницаемости по слоям между скважинами (по вертикали — слои модели, по горизонтали — связи модели).

Проницаемость, мД									
слои/ связи	1	2	3	4	5	6	7	8	9
1	7,1738	5,8528	5,7147	4,1008	5,8815	10,896	11,086	11,301	7,6318
2	45,946	20,139	40,251	19,553	27,435	67,849	60,325	34,211	21,7
3	117,89	132,94	127,23	81,537	110,84	108,35	94,415	129,16	95,33
4	93,377	102,39	77,369	64,642	96,428	67,633	65,072	80,293	95,067
5	57,544	32,844	60,554	88,37	49,658	50,398	81,69	64,267	65,799
6	43,626	51,076	44,901	63,849	86,044	56,304	53,62	67,191	88,582
7	37,398	57,1	53,689	52,163	71,863	73,974	38,953	44,913	41,973
8	65,364	59,733	81,608	25,152	70,269	65,302	73,815	88,283	57,517
9	39,785	37,316	71,115	36,908	44,834	62,541	67,866	83,297	47,623
10	34,575	39,115	29,92	26,977	27,077	31,901	28,469	26,383	34,223
11	19,485	14,031	33,766	37,083	41,42	68,475	30,311	31,144	48,581
12	17,864	43,328	39,699	53,499	48,649	25,534	13,924	28,859	27,91
13	15,967	26,212	21,551	24,916	20,768	15,107	14,335	7,6013	16,203
14	27,918	15,928	14,796	20,11	18,694	13,301	10,877	12,427	12,604
15	8,6662	16,382	17,149	18,44	13,476	13,713	11,188	10,331	11,328

Таблица 3.4 — Распределение начальной водонасыщенности по слоям между скважинами (по вертикали — слои модели, по горизонтали — связи модели).

Начальная нефтенасыщенность, % (1-Swi)									
слои/ связи	1	2	3	4	5	6	7	8	9
1	0,5573	0,5673	0,5761	0,542	0,5839	0,6118	0,4929	0,506	0,5792
2	0,6505	0,6287	0,6691	0,6227	0,6578	0,6978	0,6023	0,6223	0,6278
3	0,7128	0,727	0,7325	0,6965	0,725	0,7247	0,6533	0,688	0,7059
4	0,6973	0,7126	0,7069	0,6759	0,719	0,6998	0,6083	0,6482	0,7036
5	0,6542	0,6468	0,6934	0,6934	0,6843	0,6793	0,5591	0,5679	0,6785
6	0,6296	0,6687	0,6783	0,6703	0,7086	0,6831	0,4571	0,561	0,6868
7	0,6128	0,6721	0,6847	0,6426	0,7029	0,6939	0,4361	0,4633	0,635
8	0,6269	0,658	0,7054	0,5282	0,7021	0,6903	0,4515	0,4921	0,5933
9	0,5845	0,6378	0,6931	0,5388	0,6798	0,6833	0,428	0,4829	0,5783
10	0,5114	0,5919	0,6465	0,5218	0,6545	0,64	0,3215	0,3575	0,5552
11	0,4285	0,5395	0,6468	0,5347	0,6717	0,673	0,197	0,3566	0,5654
12	0,4129	0,5906	0,6396	0,4784	0,6811	0,6099	0,1224	0,3498	0,4832
13	0,3968	0,564	0,615	0,4395	0,6409	0,573	0,1177	0,2376	0,4503
14	0,4117	0,622	0,5565	0,4214	0,6329	0,4708	0	0,2377	0,4257
15	0,1684	0,4406	0,5632	0,4087	0,6117	0,4654	0	0,2249	0,3686

В горизонтальной оси приведены значения осредненные по всему слою, что при следующей итерации сети следует также развернуть, как все значения, которые были осреднены, а не одно на слой.

При формировании массива данных будет требоваться более сложная его структура.

$$x_i^{(k)} = \gamma^{(k)} (x_i^{(k-1)}, \varphi^{(k)} (x_i^{(k-1)}, x_j^{(k-1)}, e_{i,j})) \quad (3.1)$$

где

x — вложения узлов;

e — граничные особенности;

φ — функция сообщения;

\square — функция агрегирования;

γ — функция обновления.

Если рёбра в графе не имеют других свойств, кроме связности, е является индексом рёбер графа. Верхний индекс представляет индекс слоя. Когда $k = 1$, x представляет входную характеристику каждого узла.

Ниже приводится подробный пример использование `edge_index` для векторного массива данных.

```
{"edge_mapping": {"edge_index": {"50": [[37, 109], [37, 66], [0, 109], [22, 22], [47, 47], [41, 41], [58, 60], [93, 93], [43, 22], [37, 37], [37, 65], [10, 10], [10, 51], [115, 115], [37, 98], [32, 32], [23, 23], [22, 105], [93, 82], [12, 12], [22, 10], [90, 41], [93, 83], [0, 41], [35, 41], [35, 35], [98, 98], [0, 0], [35, 33], [37, 110], [41, 90], [90, 14], [90, 90], [90, 40], [0, 37], [74, 83], [93, 74], [82, 23].....
```

```
...[25, 0], [42, 121], [42, 28], [103, 0], [103, 91], [121, 65], [121, 0], [121, 5], [121, 128], [28, 65], [28, 57], [28, 128], [103, 64]] [34]
```

Для случая, описываемого в работе следует учитывать то, что присутствует 5 статических параметров (координаты (x, y) , пористость, проницаемость, начальная водонасыщенность), поэтому приведенная выше схема будет работать в подобном виде, только для динамического параметра, а статические параметры будут указаны перед данной записью.

4 ФИНАНСОВЫЙ МЕНЕДЖМЕНТ, РЕСУРСОЭФФЕКТИВНОСТЬ И РЕСУРСОСБЕРЕЖЕНИЕ

Нефтегазовые корпорации предпринимают шаги по увеличению операционной производительности и оптимизации процесса добычи нефти и газа. При данном многогранная производственная информация превращается в главный базисный ресурс управления функционированием передовых производственных систем, а степень применяемых информационных технологий в значимой мере определяет смысл конкурентоспособности нефтепромысла, нефтепровода или же НПЗ и др. производств.

С 2011 года в профессиональный сленг было введено понятие четвертой индустриальной («машинной») революции, которую можно описать как переход на всецело автоматизированное производство, обладающее «искусственным интеллектом» в процессе управления. Данный процесс происходит в режиме настоящего времени, находится в постоянном взаимодействии с окружающей средой, а также выходит за пределы одного предприятия. В дальнейшем имеются перспективы объединения предприятий в глобальную промышленную сеть производства.

Основные движущие силы происходящей «цифровой» революции – это повсеместное распространение элементов и устройств вычислительной техники, прежде всего: персональных компьютеров, всеобъемлющего проникновения Интернета, а также массового применения разнообразных персональных портативных коммуникационных устройств.

Результатом «цифровой» революции является повсеместный переход к «цифровой» экономике (Digital Economic), практические принципы которой заключены в концепции, получившей название «Индустрия 4.0»

При этом, концепция Индустрии 4.0 предусматривает «цифровизацию» и интеграцию всех процессов жизненного цикла производимых продуктов: начиная от процесса разработки и заканчивая процессами их логистики и

сервиса. В соответствии с концепцией Индустрии 4.0 каждый выпускаемый продукт должен иметь свой «цифровой» образ, т. е. вся информация о нем – чертежи и технология производства, правила эксплуатации, техобслуживания и утилизации – должна быть “оцифрована” и доступна для считывания устройствами и людьми.

Необходимо отметить, что данные обо всех протекающих процессах, этапах производства, деталях, сборочных узлах и получаемых на производстве продуктах должны быть доступны авторизованным пользователям в режиме реального времени в рамках единой “цифровой” сети.

В результате крупные нефтяные компании по всему миру переходят к применению «цифровых» технологий: Shell и Total используют роботов, Chevron и Shell – дроны, Statoil – 3D-визуализацию, Chevron при помощи видеоаналитики выявляет возникновение протечек на нефтепроводах, а в BP реализуется масштабный проект, связанный с применением на морских добывающих платформах промышленного Интернета вещей.

В магистерской диссертации также рассматривается применение цифровых технологий, но в более узком его понимании, когда происходит переход от того, что было ранее (от дорогостоящих лицензий на необходимые программные продукты до цен на электроэнергию для группы специалистов, а не для одного). В работе предлагается концепт перехода от использования ПО, такого как tNavigator и Petrel, к бесплатному языку программированию Python, на основе которого предлагается написать нейронную сеть, которая будет на основе определенных входных параметров рассчитывать технологические параметры скважины (на данном этапе создания — дебит скважин).

При анализе параметров и условий работы ситуаций привычных (работы в ПО) и программирование на Python по методике, изложенной в данной работе, будет рассмотрено два случая: традиционный (привычный) и предлагаемый.

Расчеты производились из ориентировочных сроков и трудовых единиц, требуемых для выполнения среднего проекта.

Таблица 4.1 — Сравнение требуемых ресурсов между вариантами.

Параметры	Ед. измерения/ стоимость	Опции	
		Традиционная	Предлагаемая
Сотрудники	человек	2	1
Petrel	лицензия	1	0
tNavigator	лицензия	1	0
Сроки выполнения	месяц	8	3

Уже по таблице 4.1 можно заметить, что в предлагаемом на уровне ресурсов требуется меньше затрат. Для полного предоставления следует оценить примерные затраты на оба варианта.

Таблица 4.2 — Экономические затраты традиционной опции.

Ресурсы	кол-во	ед.изм.
Трудовой	248*	чел./день
Денежный	9,2	млн.руб.
Лицензия Petrel	4,8	млн.руб.
Лицензия tNavigator	2,5	млн.руб.
Заработная плата сотруднику за время выполнения	1,2	млн.руб.
Электроэнергия	0,2	млн.руб.
Рабочее место	28,8	тыс.руб.
Компьютер	439,6	тыс.руб.

* — пересчет идет из соотношения, что при традиционной опции будет работать два сотрудника по 4 месяца каждый.

Таблица 4.3 — Экономические затраты предлагаемой опции.

Ресурсы	кол-во	ед.изм.
Трудовой	92	чел./день
Денежный	0,7	млн.руб.
Python	0,0	млн.руб.
Заработная плата сотруднику за время выполнения	0,4	млн.руб.
Электроэнергия	0,1	млн.руб.
Рабочее место	14,4	тыс.руб.
Компьютер	219,8	тыс.руб.

Таблица 4.4 — Экономия при переходе на предлагаемую опцию.

Ресурс	Кол-во	Ед.изм.
Трудовой	32	чел./день
Денежный	8,4	млн.руб.

Экономия в сравнении опций присутствует денежном и трудовом ресурсах (Таблица 4.4).

Денежном ресурсе присутствуют позиции «Рабочее место» и «Компьютер». В данных позициях была учтена минимальная необходимая комплектация.

«Рабочее место» — включает в себя стол, настольную лампу и стул.



Рисунок 4.1 — Комплектация рабочего места.

«Компьютер» выбран исходя из необходимых характеристик при выполнении расчетов геологических и гидродинамических моделей, а также для выполнения симуляций написанного программного кода.

При сравнении моделей была выбрана модель компьютера NANO X фирмы HyperX ориентируясь на комплектующие входящие в состав данной сборки, а также качество компьютеров от данной фирмы. Остальные комплектующие были выбраны стандартные, т.к. основное в компьютере — это системный блок, который требует тщательного подбора.



Рисунок 4.2 — HYPERPC NANO X.

5 СОЦИАЛЬНАЯ ОТВЕТСТВЕННОСТЬ

5.1 Нормативная база

Признаком того, что сотрудникам необходимо соблюдать правила техники безопасности при использовании компьютера, становится то, что эти вопросы зафиксированы и в действующем законодательстве. Основными нормативными документами, которые содержат обязательные требования, можно считать:

5.2 Трудовой кодекс

Санитарно-гигиенические нормы и правила СанПиН 2.2.2/2.4.1340-03, утвержденные постановлением Главного государственного санврача от 13 июня 2003 года N 118 [2];

Межгосударственный стандарт ГОСТ 12.0.003-2015, который содержит список основных вредных и опасных производственные факторов и их классифицирующие признаки [4];

Типовая инструкция ТОИ Р-45-084-01, в которой содержатся основные правила для работников, использующих компьютер [5];

Требования перечисленных правовых актов, в которых содержатся общие правила защиты персонала при выполнении трудовых обязанностей и техника безопасности во время работы за компьютером, обязательны к исполнению всеми работниками этой категории.

5.3 Вредоносные факторы

Использование персонального компьютера несет вред при несоблюдении правил безопасности. Это подтверждается информацией, содержащейся в стандарте ГОСТ 12.0.003-2015 [4], описывающем основные вредные и опасные факторы трудового процесса. В их список входят:

Высокая температура, характерная для отдельных элементов компьютерной техники и создающая общий повышенный температурный фон в рабочем помещении;

Высокая степень монотонности рабочего процесса;

Значительный уровень зрительных нагрузок, испытываемых работником;

Риск поражения статическим электричеством при случайном контакте с отдельными элементами техники;

Недостаточная освещенность рабочей зоны;

Повышенный уровень напряженности электрического и магнитного полей, генерируемых работающей техникой;

Высокий уровень блёскости и контрастности рабочего экрана, негативно влияющий на зрение работника в длительной перспективе;

5.4 Гигиенические требования

В связи с наличием воздействия большого списка вредоносных факторов на работника, требования техники безопасности при работе с компьютером охватывают не только сам процесс труда, но и сопровождающие его обстоятельства, которые также влияют на работоспособность и сохранность здоровья сотрудника на длинных временных горизонтах. Соответствующие правила организации рабочего

процесса приведены в СанПиН 2.2.2/2.4.1340-03 [2]. Они включают ряд нормативов, которые касаются следующих моментов:

- общие правила организации работы с использованием компьютерной и офисной техники;
- требования к персональному компьютеру, используемому для постоянной работы сотрудника;
- требования к помещениям, в которых выполняется работа с применением офисной техники;
- требования к микроклимату для соответствующих рабочих мест, включая содержание в воздухе рабочей зоны аэроионов и вредных химикатов;
- допустимый уровень шума, генерируемого рабочим оборудованием;
- правила организации освещения рабочей зоны;
- разрешенные нормативы в отношении параметров электромагнитных полей на рабочих местах;
- техника безопасности при пользовании компьютером, которая связана с организацией рабочих мест сотрудников;
- медицинский контроль за здоровьем персонала;
- порядок организации государственного санитарно-эпидемиологического надзора и выполнения производственного контроля.

5.5 Инструктаж по технике безопасности за компьютером

Чтобы донести до работника требования, которые устанавливает техника безопасности при использовании компьютера, работодатель обязан организовать инструктаж. Он проводится на основании специально составленной инструкции, которую обычно разрабатывает специалист по охране труда или непосредственный руководитель работника. Проведение инструктажа нужно организовать до начала самостоятельной работы:

специалист допускается к работе только после его прохождения. Это значит, до него донесены правила техники безопасности при работе с компьютером. Инструкция-памятка по технике безопасности за компьютером должна быть выдана каждому работнику в бумажном или электронном виде. Ей можно дать вид легкочитаемой инфографики – например, 10 правил техники безопасности за компьютером.

5.6 Меры безопасности перед началом работы

В рамках проведения инструктажа до работника доводятся сведения о необходимых действиях, выполняемых на каждом этапе рабочего процесса [5]. Техника безопасности в начале работы на компьютере требует выполнения следующих операций:

- проверить исправность элементов электросистемы, обеспечивающей питание компьютера, включая электропроводку, выключатели, вилки и розетки, при помощи которых аппаратура подключается к сети;
- проконтролировать заземление компьютера;
- проверить его работоспособность [5].

5.7 Техника безопасности возле компьютера в процессе работы

При выполнении работ нужно соблюдать следующие правила:

- запрещается класть на корпус и дисплей компьютера посторонние предметы, прикасаться к элементам аппаратуры мокрыми руками, производить чистку корпуса оборудования, находящегося под напряжением, располагать технику близко к жилищно-коммунальным инженерным системам [5];

- в случае обнаружения неисправности компьютера немедленно прекратить работу и сообщить об этом непосредственному руководителю;
- эксплуатировать компьютер только с соблюдением инструкции, установленной производителем;
- избегать частого и необоснованного включения и выключения компьютера во время работы [5].
- Техника безопасности по окончании работы за компьютером
- После завершения работы сотруднику нужно выполнить следующие действия:
 - выключить компьютер с использованием алгоритма, установленного производителем;
 - обесточить периферийное оборудование;
 - убедиться в отключении техники;
 - выполнить очистку рабочих поверхностей влажной тканью.

5.8 Рекомендованное положение тела при сидячей работе

5.8.1 Положение ног при работе за компьютером

Ортопеды уверены, что хорошую осанку невозможно сохранить, если ставить ноги в положении сидя неправильно. Даже если стараться постоянно держать спину прямой — идеальных условий для поддержки позвоночного столба без правильного положения ног создать не получится.

Ноги должны быть обязательно согнуты под прямым углом — 90 градусов (можно чуть больше, но незначительно). При этом ступни важно располагать непосредственно на полу. Также не стоит принимать только на первый взгляд кажущуюся удобной позу "нога за ногу" — это может

привести к застою крови, а также перенапряжению мышц, что со временем приведет к обязательным болезням не только ног, но и всего организма [5].




Рисунок 5.1 — Схема рабочего места на ПК [5].

5.8.2 Положение спины и шеи при работе на ПК

Среди самых характерных ошибок людей при сидячей позе — неправильное положение спины. Чтобы сбалансировать нагрузку некоторые стараются расположиться "зигзагом" или неправильно вытянуть шею для принятия ложной комфортной позы. Все эти положения не являются удобными, кроме того могут привести к компрессии позвонков.

Весь позвоночник буквально сжимается при неправильной сидячей позе — если долго находиться в таком положении позвонки могут начать разрушаться, межпозвоночные диски существенно истончаются — в результате может разрушиться и сам хрящ, лечение которого является весьма дорогостоящим.

Многие предпочитают постоянно сидеть, сгорбившись за столом — неправильная привычка, приобретенная ещё с детства, является первым шагом к серьезным заболеваниям опорно-двигательного аппарата. Только многие симптомы проявляются не сразу — сидячая работа может дать знать о себе через несколько лет. При сидячей работе важно не откидывать спину назад или вперёд. От позвоночника отходит 32 важных нерва, которые легко можно защемить при длительной неправильной позе, а это может привести к нарушению деятельности многих органов. Плечи важно расположить таким образом, чтобы лопатки "смотрели" друг на друга. Подбородок необходимо слегка потянуть на себя — это позволит правильно держать шею и располагать шейные позвонки по всем правилам, предотвращая смещение [5].



Рисунок 5.2 — Регулировка офисного стула.

Если вы используете правильный ортопедический стул, можно периодически принимать позу "откинувшись" на спинку — нагрузка на мышцы спины будет правильно распределена.

5.8.3 Усталость глаз от компьютера

Во время интернет-серфинга или непосредственной работы с документацией важно не только принять правильную сидячую позу за рабочим столом, но и позаботиться о зрении. Прежде всего, важно проверить угол освещения — яркий источник света должен обязательно находиться под углом 90 градусов относительно экрана монитора — в таком случае появление бликов исключено, как известно именно они могут существенно портить зрение.

Работая за компьютером длительное время, важно не забывать о зрительной зарядке — некоторые стандартные упражнения помогут снизить риск ухудшения зрения в разы.

5.8.4 Правильное положение рук

Руки при сидячей работе за компьютером испытывают особую нагрузку. Их рекомендуется держать в согнутом положении — 90 градусов. При этом специалисты не рекомендуют опираться локтями на стол — это может привести к зажиму некоторых мышц. При длительном печатании может появиться дискомфорт в запястье — для этого специалистами разработаны специальные коврики для мыши, ортопедические клавиатуры, а также специальные подставки для рук.

Строго не рекомендуется "выдерживать" угол более 120 градусов — особенно это касается тех, кто привык работать с мышкой. Нагрузка на запястье при таком значении существенно возрастает, и при длительной работе могут возникнуть сильные боли. Клавиатуру и мышь необходимо располагать на одном уровне (правильное положение будет примерно на уровне локтя).

Мышка должна быть максимально удобной — на сегодняшний день разработаны специальные приспособления для геймеров и графических редакторов, которым приходится наиболее часто работать с мышью. Специальные игровые мышки обладают дополнительными функциональными приспособлениями, а графические варианты обеспечивают максимальную точность наведения курсора.



Рисунок 5.3 — Правильное положение руки на мышке.

Существуют также специальные коврики для мышки с подвижной опорой, которые могут правильно отрегулировать положение и снять нагрузку с рук. При работе за компьютером длительное время важно периодически разминать пальцы и делать специальные массирующие упражнения для мышц рук.

При непосредственной печати запястья должны "нависать" над клавиатурой — это необходимо для того, чтобы в работу были при необходимости включены все пальцы. Правильная ортопедическая клавиатура может содержать специальное приспособление в виде подставки. Функциональная подставка под клавиатуру может удобно регулироваться по

высоте — в зависимости от индивидуальных особенностей можно зафиксировать правильное положение для комфортной печати.




Рисунок 5.4 — Правильное положение руки на клавиатуре.

С медицинской точки зрения клавиатура должна быть максимально удобной — нажатие на клавиши не должно требовать особых усилий, поскольку при печати не должно чувствоваться ни единого напряжения в запястьях. Правильная подставка поможет держать руки на клавишах правильно — всё это позволит значительно снизить общую нагрузку на мышцы.

5.8.5 Правильная настройка стола при работе за компьютером

Для создания по-настоящему комфортных условий при работе за компьютером одной настройки кресла недостаточно, очень важной является настройка высоты стола в зависимости от Вашего роста. К сожалению, высота большинства офисных, компьютерных или письменных столов

варьируется в диапазоне от 72 до 78 см, в редких случаях есть возможность регулировки, еще плюс минус 2-3 см. Но этого явно недостаточно для людей, рост которых может быть, как 150, так и все 200 см. Ниже приведена размерная таблица с рекомендациями по регулировке высоты кресла и стола в зависимости от роста пользователя.

Таблица 5.1 — Размерная таблица с рекомендациями по регулировке высоты кресла и стола.

рост	высота сидения	высота рабочей поверхности стола при работе сидя	высота рабочей поверхности стола при работе стоя
152 см	36 см	57 см	93 см
155 см	37 см	58 см	94 см
157 см	38 см	59 см	95 см
160 см	38 см	60 см	97 см
163 см	39 см	61 см	99 см
165 см	40 см	62 см	101 см
168 см	41 см	63 см	102 см
170 см	41 см	64 см	104 см
173 см	42 см	65 см	106 см
рост	высота сидения	высота рабочей поверхности стола при работе сидя	высота рабочей поверхности стола при работе стоя
175 см	43 см	66 см	108 см
178 см	44 см	67 см	109 см
180 см	44 см	68 см	111 см
183 см	46 см	68 см	112 см
185 см	46 см	69 см	113 см
188 см	48 см	71 см	116 см
191 см	48 см	72 см	117 см
193 см	49 см	72 см	119 см
195 см	49 см	73 см	120 см

Под высотой стола подразумевается расстояние от пола до рабочей поверхности, на которой установлена клавиатура. Вспомогательные устройства могут быть размещены не только на рабочем столе, но и, например, на полке (лотке) для клавиатуры, которая в зависимости от конструкции может не только выезжать из-под стола, но и менять угол наклона и даже высоту. Важно сидеть максимально глубоко в кресле и максимально близко к краю стола, так, чтобы вы не тянулись к клавиатуре, в этом случае любая спинка будет не функциональна, ведь нагрузка должна равномерно распределяться, а это возможно только в слегка отклоненном

назад положении. Так же важно настроить высоту дисплея на уровень глаз и на расстояние «вытянутой руки».

В последнее время появилось множество всевозможных надстроек на офисные столы: конвертеры, регулируемые стенды, платформы для работы сидя-стоя, настольные кронштейны для монитора и клавиатуры. Все эти новшества могут использоваться в паре с обычным, не регулируемым по высоте столом, для того, чтобы пользователь мог легко менять положение сидя на стоя. Чередование режимов работы, периодическое перераспределение нагрузки, позволяет оставаться в хорошей физической форме даже после многочасового рабочего дня. Специалисты рекомендуют обратить особое внимание при создании комфортной рабочей среды, удобного рабочего места для того что сохранить здоровье, на котором конечно не стоит экономить.

5.8.6 Дыхание во время работы за компьютером

О дыхании мало кто заботится во время работы за компьютером — на первый взгляд здесь не может возникнуть особых проблем, связанных со здоровьем лёгких. Но когда речь идёт о постоянной работе за компьютером, могут возникнуть некоторые последствия.

У чувствительных людей могут возникнуть самые разнообразные аллергические реакции — при этом в качестве аллергенов могут выступать системный блок и даже монитор. Люди, склонные к аллергии, могут ощутить недомогание — у них возникает кашель, головная боль, в некоторых случаях существует риск отека слизистых оболочек [1].

Специалисты советуют, как можно чаще проветривать помещение, в котором находится компьютер — свежий воздух в сочетании с ежедневной

влажной уборкой помогут избежать многих проблем, связанных с болезнями органов дыхания.

Ученые рекомендуют избавляться от этого опасного состояния и советуют дышать глубоко и ровно во время работы за компьютером. Иначе можно получить целый ряд заболеваний — усиленное сердцебиение, нарушение работы мозга, повышенное потоотделение и другие неприятные последствия.

5.8.7 Условия работы за компьютером (температура, влажность, освещенность)

Существуют некоторые параметры оптимального микроклимата, которые необходимо создавать при длительной работе за компьютером. Стандартными условиями считаются:

оптимальная температура воздуха в помещении (19-20 градусов);

влажность воздуха должна составлять от 62 до 55%;

рабочий стол должен быть оснащен хорошей настольной лампой, обеспечивающей качественное освещение.

Оптимальным вариантом является искусственное освещение, поскольку яркий солнечный свет может давать сильные блики на экран — не рекомендуется устанавливать рабочий стол прямо у окна.

При соблюдении данных параметров можно организовать достаточно комфортные условия для постоянной работы за компьютером — если правильно организовать рабочее место и освещенность, существует вероятность значительно оградить организм от вредных факторов [2].

5.9 Режимы труда и отдыха

Режимы труда и отдыха, время начала и окончания смен, перерывы для отдыха и обеденные перерывы определяются работодателем с соблюдением установленной законодательством продолжительности рабочего времени и по согласованию с соответствующими выборными профсоюзными органами с учетом специфики работы и мнения трудового коллектива и закрепляются в правилах внутреннего трудового распорядка, утверждаемого общим собранием (конференцией) работников организации по представлению администрации.

При сменном режиме работы переход из одной смены в другую должен происходить, как правило, через каждую неделю в часы, определенные графиком сменности.

До начала работы каждый работающий обязан отметить свой приход на работу, а по окончании рабочего дня - уход с работы в порядке, установленном на предприятии.

Руководитель структурного подразделения (цеха, участка) обязан организовать учет явки на работу и ухода с работы.

При установлении режимов труда и отдыха должны учитываться степени опасности и вредности сопутствующих процессам производственных факторов [5].

Для поддержания оптимальной работоспособности станочников на протяжении смены должно устанавливаться чередование периодов работы и отдыха с учетом степени тяжести и напряженности труда, а также условий труда на рабочем месте. Перерыв на обед должен назначаться через 3,5 - 4 часа после начала смены и иметь продолжительность 45 - 60 мин. В течение смены рекомендуется предусматривать два перерыва: первый - через 2 - 2,5 часа после начала смены длительностью 5 мин, второй - за 1,5 - 2 часа до конца смены продолжительностью 10 мин.

При работах стоя первый перерыв должен использоваться для пассивного отдыха, второй перерыв - для выполнения специального комплекса гимнастических упражнений.

В соответствии с СанПиНом 2.2.2.540-96 [1] и разработанного на их основе "Положения. Вибрационная безопасность. Режимы труда работников виброопасных профессий (ПОТ РО-14000-006-98)" [3], при этом:

Суммарное время работы в контакте с ручными машинами, генерирующими вибрацию в пределах санитарных норм, не должно превышать 480 минут (с учетом двух регламентированных перерывов).

Сверхурочные работы с виброопасным инструментом запрещены.

Допустимое суммарное время работы в контакте с локальной вибрацией должно определяться в зависимости от уровней вибрации почасовыми циклами в течение смены;

Структура одночасового цикла должна устанавливаться с учетом того, что время одноразового непрерывного воздействия вибрации не должно превышать 10 - 15 мин., а соотношение времени воздействия вибрации и следующего за ним времени, не связанного с воздействием вибрации, должно соотноситься не более чем 1:1;

Время регламентированных перерывов продолжительностью 20 и 30 мин., устраиваемых через 1 - 2 часа после начала смены и через 2 часа после обеденного перерыва, должно включаться в норму выработки;

При работах с машинами, генерирующими вибрацию, рекомендуется организация комплексных бригад с взаимозаменяемостью профессий и введением внутрисменных режимов с чередованием циклов труда и отдыха;

При воздействии на работающих виброопасных профессий других неблагоприятных факторов (шума, температуры, излучения, запыленности, загазованности), превышающих санитарные нормы, статической нагрузки, рабочей позы и др., режимы труда и отдыха должны устанавливаться с учетом степени неблагоприятного воздействия всего комплекса факторов.

Регламентированные перерывы следует использовать для проведения комплекса гимнастических упражнений, активного отдыха, лечебно-профилактических мероприятий и процедур.

Администрация организации, эксплуатирующей виброопасное оборудование, обязана:

Обеспечить разработку и внедрение режимов труда для работников виброопасных профессий;

К эксплуатации допускать технически исправные машины, проверенные по вибрационным параметрам. Для чего на предприятии должен быть организован централизованный ремонт этого оборудования и установлен строгий контроль за его состоянием с замером вибрационных характеристик и внесением данных контроля в паспорта на это оборудование;

Обеспечить организацию, оборудование и работу помещений для приема лечебно-профилактических процедур под контролем медицинских работников.

В целях предупреждения вибрационной болезни у работающих с оборудованием, генерирующим вибрации, рекомендуется в комплексе с рациональным построением их режима труда, по заключению органов санитарного надзора, проведение комплекса физиопрофилактических мероприятий (водных процедур, массажа, лечебной гимнастики, ультрафиолетового облучения, витаминизации и др.).

ЗАКЛЮЧЕНИЕ

Также при написании магистерской диссертации была подтверждена актуальность темы в увеличивающейся популярностью данной темы в научных кругах и все новых ее применениях.

Целью данной работы являлось использование теории графов с для адаптации гидродинамической модели и расчета технологических показателей работы скважин с учетом возможности масштабирования указанной методики на верхнеюрские отложения.

Для достижения поставленной цели были сформулированы следующие задачи:

- Изучить язык программирования «Python» на базовом уровне;
- Ознакомиться с разновидностями нейронных сетей, изучить основы работы с графовыми нейронными сетями;
- Применить графовые нейронные сети с целью адаптации гидродинамической модели SRM-6 и расчета технологических показателей работы скважин;

Был выполнен литературный обзор по нейронным сетям и, в частности, применения графовых нейронных сетей для решения схожих по тематике исследования задач.

В качестве входных параметров для графовой нейронной сети, на основе модели SRM-6, были приняты пять статических параметров (координаты скважин — x , y , а также пористость, проницаемость и начальная водонасыщенность) и один динамический параметр (дебит жидкости). Для первого базового применения методики было решено провести расчет на семи годах исторических данных. Принять первые шесть лет в качестве обучающей выборки и один, седьмой год, – проверочной выборки.

Во время реализации указанной методики в рамках магистерской диссертации не удалось довести до заявленной цели, поэтому была применена другая нейронная сеть, во основе которой не лежит графовое

представление нейронных сетей, но она также выполняет функцию прогнозирования технологических параметров скважин.

Актуальность и привлекательность графовой нейронной сети остается неизменной, и в будущем данная методика будет доработана и осуществлена, а также планируется глубже рассмотреть физику пласта и реализовать методику, которая учитывает связь скважин каждой с каждой.

При использовании другой нейронной сети был сформирован массив данных, состоящий из значений дебита за шесть лет работы месторождения.

Фактически использованная нейронная сеть также решает проблему прогнозирования технологических параметров скважин. Более того, ее можно использовать также при прогнозировании темпов падения добычи для скважин отдельно или месторождений в целом, а также при прогнозировании характеристик вытеснения нефти на основе запускных параметров и накопленной добычи.

Результатом выполненной работы может считаться концепция методики применения графовых нейронных сетей для адаптации гидродинамической модели и расчета технологических показателей работы скважин, которая будет доработана и опробована на синтетическом месторождении SRM-6. А также применение рекуррентной нейронной сети для прогнозирования темпа падения добычи на рассматриваемом участке месторождения.

Было произведена сравнительная оценка эффективности предлагаемого подхода с методом, предполагающим использование программных продуктов для геологического и гидродинамического моделирования. Предлагаемый подход на 90% менее затратен с финансовой точки зрения и на 60% требует меньше временных ресурсов.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Гигиенические требования к микроклимату производственных помещений. СанПиН 2.2.4.548-96. - М.: ДЕАН, 1996.
2. Гигиенические требования к персональным электронно-вычислительным машинам и организации работы. СанПиН 2.2.2/2.4.1340 – 03. - М.: ДЕАН, 2003.
3. Работы с повышенной опасностью. ПОТ РО-14000-006-98. - М.: ДЕАН, 1998.
4. Система стандартов безопасности труда. ГОСТ 12.0.003-2015. - М.: ДЕАН, 2015.
5. Типовая инструкция по охране труда при работе на персональном компьютере. ТОИ Р-45-084-01. - М.: ДЕАН, 2001.
6. J. Atwood and D. Towsley, “Diffusion-convolutional neural networks,” in Proc. of NIPS, 2016, pp. 1993–2001.
7. D. Bacciu, F. Errica, and A. Micheli, “Contextual graph markov model: A deep and generative approach to graph processing,” in Proc. of ICML, 2018.
8. P. W. Battaglia, J. B. Hamrick, V. Bapst, A. Sanchez-Gonzalez, V. Zambaldi, M. Malinowski, A. Tacchetti, D. Raposo, A. Santoro, R. Faulkner et al., “Relational inductive biases, deep learning, and graph networks,” arXiv preprint arXiv:1806.01261, 2018.
9. Bing Yu, Haoteng Yin, and Zhanxing Zhu. 2018. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. In Proc. of IJCAI. 3634–3640.
10. J. Bruna, W. Zaremba, A. Szlam, and Y. LeCun, “Spectral networks and locally connected networks on graphs,” in Proc. of ICLR, 2014.
11. H. Cai, V. W. Zheng, and K. Chang, “A comprehensive survey of graph embedding: problems, techniques and applications,” IEEE Transactions on Knowledge and Data Engineering, 2018.

12. J. Chen, T. Ma, and C. Xiao, “Fastgcn: fast learning with graph convolutional networks via importance sampling,” in Proc. of ICLR, 2018.
13. J. Chen, J. Zhu, and L. Song, “Stochastic training of graph convolutional networks with variance reduction,” in Proc. of ICML, 2018, pp. 941–949
14. P. Cui, X. Wang, J. Pei, and W. Zhu, “A survey on network embedding,” IEEE Transactions on Knowledge and Data Engineering, 2017.
15. H. Dai, Z. Kozareva, B. Dai, A. Smola, and L. Song, “Learning steadystates of iterative algorithms over graphs,” in Proc. of ICML, 2018, pp. 1114–1122.
16. M. Defferrard, X. Bresson, and P. Vandergheynst, “Convolutional neural networks on graphs with fast localized spectral filtering,” in Proc. of NIPS, 2016, pp. 3844–3852.
17. C. Gallicchio and A. Micheli, “Graph echo state networks,” in IJCNN. IEEE, 2010, pp. 1–8.
18. H. Gao, Z. Wang, and S. Ji, “Large-scale learnable graph convolutional networks,” in Proc. of KDD. ACM, 2018, pp. 1416–1424.
19. “Neural message passing for quantum chemistry,” in Proc. of ICML, 2017, pp. 1263–1272.
20. P. Goyal and E. Ferrara, “Graph embedding techniques, applications, and performance: A survey,” Knowledge-Based Systems, vol. 151, pp. 78–94, 2018.
21. M. Gori, G. Monfardini, and F. Scarselli, “A new model for learning in graph domains,” in Proc. of IJCNN, vol. 2. IEEE, 2005, pp. 729–734.
22. W. Hamilton, Z. Ying, and J. Leskovec, “Inductive representation learning on large graphs,” in Proc. of NIPS, 2017, pp. 1024–1034.
23. W. L. Hamilton, R. Ying, and J. Leskovec, “Representation learning on graphs: Methods and applications,” in Proc. of NIPS, 2017, pp. 1024–1034.
24. M. Henaff, J. Bruna, and Y. LeCun, “Deep convolutional networks on graph-structured data,” arXiv preprint arXiv:1506.05163, 2015.

25. G. Hinton, L. Deng, D. Yu, G. E. Dahl, A.-r. Mohamed, N. Jaitly, A. Senior, V. Vanhoucke, P. Nguyen, T. N. Sainath et al., “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups,” *IEEE Signal processing magazine*, vol. 29, no. 6, pp. 82–97, 2012.
26. S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
27. T. N. Kipf and M. Welling, “Semi-supervised classification with graph convolutional networks,” in *Proc. of ICLR*, 2017.
28. N. M. Kriege, F. D. Johansson, and C. Morris, “A survey on graph kernels,” *arXiv preprint arXiv:1903.11835*, 2019.
29. R. Li, S. Wang, F. Zhu, and J. Huang, “Adaptive graph convolutional neural networks,” in *Proc. of AAAI*, 2018, pp. 3546–3553.
30. Y. LeCun, Y. Bengio et al., “Convolutional networks for images, speech, and time series,” *The handbook of brain theory and neural networks*, vol. 3361, no. 10, p. 1995, 1995.
31. J. B. Lee, R. A. Rossi, S. Kim, N. K. Ahmed, and E. Koh, “Attention models in graphs: A survey,” *arXiv preprint arXiv:1807.07984*, 2018.
32. R. Levie, F. Monti, X. Bresson, and M. M. Bronstein, “Cayleynets: Graph convolutional neural networks with complex rational spectral filters,” *IEEE Transactions on Signal Processing*, vol. 67, no. 1, pp. 97–109, 2017.
33. Y. Li, D. Tarlow, M. Brockschmidt, and R. Zemel, “Gated graph sequence neural networks,” in *Proc. of ICLR*, 2015.
34. M.-T. Luong, H. Pham, and C. D. Manning, “Effective approaches to attention-based neural machine translation,” in *Proc. of EMNLP*, 2015, pp. 1412–1421.
- A. Micheli, “Neural network for graphs: A contextual constructive approach,” *IEEE Transactions on Neural Networks*, vol. 20, no. 3, pp. 498–511, 2009.

35. F. Monti, D. Boscaini, J. Masci, E. Rodola, J. Svoboda, and M. M. Bronstein, “Geometric deep learning on graphs and manifolds using mixture model cnns,” in Proc. of CVPR, 2017, pp. 5115–5124.
36. N. Navarin and A. Sperduti, “Approximated neighbours minhash graph node kernel.” in Proc. of ESANN, 2017.
37. M. Niepert, M. Ahmed, and K. Kutzkov, “Learning convolutional neural networks for graphs,” in Proc. of ICML, 2016, pp. 2014–2023.
38. S. Pan, J. Wu, X. Zhu, C. Zhang, and Y. Wang, “Tri-party deep network representation,” in Proc. of IJCAI, 2016, pp. 1895–1901.
39. B. Perozzi, R. Al-Rfou, and S. Skiena, “Deepwalk: Online learning of social representations,” in Proc. of KDD. ACM, 2014, pp. 701–710.
40. J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in Proc. of CVPR, 2016, pp. 779–788.
41. S. Ren, K. He, R. Girshick, and J. Sun, “Faster r-cnn: Towards realtime object detection with region proposal networks,” in Proc. of NIPS, 2015, pp. 91–99.
42. F. Scarselli, M. Gori, A. C. Tsoi, M. Hagenbuchner, and G. Monfardini, “The graph neural network model,” IEEE Transactions on Neural Networks, vol. 20, no. 1, pp. 61–80, 2009.
43. Shang, C., Tang, Y., Huang, J., Bi, J., He, X., Zhou, B., 2019. End-to-end structure-aware convolutional networks for knowledge base completion. Proceedings of AAAI 33, 3060–3067.
44. X. Shen, S. Pan, W. Liu, Y.-S. Ong, and Q.-S. Sun, “Discrete network embedding,” in Proc. of IJCAI, 2018, pp. 3549–3555.
45. N. Shervashidze, P. Schweitzer, E. J. v. Leeuwen, K. Mehlhorn, and K. M. Borgwardt, “Weisfeiler-lehman graph kernels,” Journal of Machine Learning Research, vol. 12, no. Sep, pp. 2539–2561, 2011.
46. Shuman, D.I., Narang, S.K., Frossard, P., Ortega, A., Vandergheynst, P., 2013. The emerging field of signal processing on graphs: extending high-

dimensional data analysis to networks and other irregular domains. *IEEE SPM* 30, 83–98.

47. Shchur, O., Zugner, D., Bojchevski, A., Gunnemann, S., 2018b. Netgan: generating graphs via random walks. In: *Proceedings of ICML*, pp. 609–618.
48. Sperduti and A. Starita, “Supervised neural networks for the classification of structures,” *IEEE Transactions on Neural Networks*, vol. 8, no. 3, pp. 714–735, 1997.
49. D. V. Tran, A. Sperduti et al., “On filter size in graph convolutional networks,” in *SSCI. IEEE*, 2018, pp. 1534–1541.
50. P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol, “Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion,” *Journal of machine learning research*, vol. 11, no. Dec, pp. 3371–3408, 2010.
51. P. Velickovic, G. Cucurull, A. Casanova, A. Romero, P. Lio, and Y. Bengio, “Graph attention networks,” in *Proc. of ICLR*, 2017.
52. S. V. N. Vishwanathan, N. N. Schraudolph, R. Kondor, and K. M. Borgwardt, “Graph kernels,” *Journal of Machine Learning Research*, vol. 11, no. Apr, pp. 1201–1242, 2010.
53. Y. Wu, M. Schuster, Z. Chen, Q. V. Le, M. Norouzi, W. Macherey, M. Krikun, Y. Cao, Q. Gao, K. Macherey et al., “Google’s neural machine translation system: Bridging the gap between human and machine translation,” *arXiv preprint arXiv:1609.08144*, 2016.
54. H. Yang, S. Pan, P. Zhang, L. Chen, D. Lian, and C. Zhang, “Binarized attributed network embedding,” in *Proc. of ICDM. IEEE*, 2018.
55. Zhong, W., Xu, J., Tang, D., Xu, Z., Duan, N., Zhou, M., Wang, J., Yin, J., 2020. Reasoning over semantic-level graph for fact checking. *Proceedings of ACL* 6170–6180.

56. J. Zhang, X. Shi, J. Xie, H. Ma, I. King, and D.-Y. Yeung, “Gaan: Gated attention networks for learning on large and spatiotemporal graphs,” in Proc. of UAI, 2018.
57. D. Zhang, J. Yin, X. Zhu, and C. Zhang, “Network representation learning: A survey,” IEEE Transactions on Big Data, 2018.
58. C. Zhuang and Q. Ma, “Dual graph convolutional networks for graphbased semi-supervised classification,” in WWW, 2018, pp. 499–508.
59. GeekBrains [электронный ресурс] // URL: https://gb.ru/courses/950?utm_source=aff&utm_medium=cpa&utm_campaign=aff_cpa_admitad&utm_content=1274282&utm_term=31d7100f5bf2e91c16ccad55e1b20696 (дата обращения: 02.03.2021)
60. Synthetic Reservoir Model [электронный ресурс] // URL: <https://hwtru.info/en/srm/> (дата обращения: 20.03.2021).


Приложение А
(справочное)

**Application of graph theory in the calculation of technological characteristics
of wells on the example of the synthetic field SRM-6**


Студент

Группа	ФИО	Подпись	Дата
2ТМ91	Вальман Никита Константинович		25.05.21

Руководитель

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОНД	Матвеев И.В.	к.ф.-м.н.		25.05.21

Консультант-лингвист отделения иностранных языков ШБИП

Должность	ФИО	Ученая степень, звание	Подпись	Дата
Доцент ОНД	Уткина А.Н.	к.филос.н.		25.05.21

BACKGROUNDS

Multivariate Time Series Forecasting

Time series forecasting has been studied for a long time. The majority of existing methods follow a statistical approach [4]. The autoregressive integrated moving average (ARIMA) generalizes a family of a linear model, including autoregressive (AR), moving average (MA), and auto-regressive moving average (ARMA). The vector auto-regressive model (VAR) extends the AR model to capture the linear interdependencies among multiple time series. Similarly, the vector auto-regressive moving average model (VARMA) is proposed as a multivariate version of the ARMA model. Gaussian process (GP), as a Bayesian approach, models the distribution of a multivariate variable over functions. GP can be applied naturally to model multivariate time series data. Although statistical models are widely used in time series forecasting due to their simplicity and interpretability, they make strong assumptions with respect to a stationary process and they do not scale well to multivariate time series data. Deep-learning-based approaches are free from stationary assumptions and they are effective methods to capture non-linearity. Lai et al. and Shih et al. are the first two deep-learning-based models designed for multivariate time series forecasting. They employ convolutional neural networks to capture local dependencies among variables and recurrent neural networks to preserve long-term temporal dependencies. Convolutional neural networks encapsulate interactions among variables into a global hidden state. Therefore, they cannot fully exploit latent dependencies between pairs of variables.

Graph Neural Networks

Graph neural networks have enjoyed great success in handling spatial dependencies among entities in a network. Graph neural networks assume that the state of a node depends on the states of its neighbors. To capture this type of spatial dependency, various kinds of graph neural networks have been developed through message passing, information propagation, and graph convolution. Sharing

similar roles, they essentially capture a node’s highlevel representation by passing information from a node’s neighbors to the node itself. Most recently, we have seen the emergence of a type of graph neural networks known as spatial-temporal graph neural networks. This form of neural networks is proposed initially to solve the problem of traffic prediction [2, 5, 6] and skeleton-based action recognition. The inputs to spatialtemporal graph neural networks are multivariate time series with an external graph structure which describes the relationships among variables in multivariate time series. For spatial-temporal graph neural networks, spatial dependencies among nodes are captured by graph convolutions, while temporal dependencies among historical states are preserved by recurrent neural networks [2] or 1D convolutions [6]. Although existing spatial-temporal graph neural networks have achieved significant improvements compared to methods without using a graph structure, they are incapable of handling pure multivariate time series data effectively due to the absence of a pre-defined graph and lack of a general framework.

PROBLEM FORMULATION

In this paper, we focus on the task of multivariate time series forecasting. Let $z_t \in \mathbb{R}^N$ denote the value of a multivariate variable of dimension N at time step t , where $z_t [i] \in \mathbb{R}$ denote the value of the i^{th} variable at time step t . Given a sequence of historical P time steps of observations on a multivariate variable, $X = \{z_{t_1}, z_{t_2}, \dots, z_{t_P}\}$, our goal is to predict the Q -step-away value of $Y = \{z_{t_P+Q}\}$, or a sequence of future values $Y = \{z_{t_P+1}, z_{t_P+2}, \dots, z_{t_P+Q}\}$. More generally, the input signals can be coupled with other auxiliary features such as time of the day, day of the week, and day of the season. Concatenating the input signals with auxiliary features, we assume the inputs instead are $X = \{S_{t_1}, S_{t_2}, \dots, S_{t_P}\}$ where $S_{t_i} \in \mathbb{R}^{N \times D}$, D is the feature dimension, the first column of S_{t_i} equals to z_{t_i} , and the rest are auxiliary features. We aim to build a mapping $f(\cdot)$ from X to Y by minimizing the absolute loss with l_2 regularization.

Graphs describe the relationships among entities in a network. We give a formal definition of graph-related concepts below.

Definition 1 (Graph). A graph is formulated as $G = (V, E)$ where V is the set of nodes, and E is the set of edges. We use N to denote the number of nodes in a graph.

Definition 2 (Node Neighborhood). Let $v \in V$ to denote a node and $e = (v,u) \in E$ to denote an edge pointing from u to v . The neighborhood of a node v is defined as $N(v) = \{u \in V | (v,u) \in E\}$.

Definition 3 (Adjacency Matrix). The adjacency matrix is a mathematical representation of a graph, denoted as $A \in \mathbb{R}^{N \times N}$ with $A_{ij} = c > 0$ if $(v_i, v_j) \in E$ and $A_{ij} = 0$ if $(v_i, v_j) \notin E$.

From a graph-based perspective, we consider variables in multivariate time series as nodes in graphs. We describe the relationships among nodes using the graph adjacency matrix. The graph adjacency matrix is not given by the multivariate time series data in most cases and will be learned by our model.

FRAMEWORK OF MTGNN

Model Architecture

We first elaborate on the general framework of our model. As illustrated in Figure 1, MTGNN on the highest level consists of a graph learning layer, m graph convolution modules, m temporal convolution modules, and an output module. To discover hidden associations among nodes, a graph learning layer computes a graph adjacency matrix, which is later used as an input to all graph convolution modules. Graph convolution modules are interleaved with temporal convolution modules to capture spatial and temporal dependencies respectively. Figure 2 gives a demonstration of how a temporal convolution module and a graph convolution module collaborate with each other. To avoid the problem of gradient vanishing, residual connections are added from the inputs of a temporal convolution module to the outputs of a graph convolution module. Skip connections are added after

each temporal convolution module. To get the final outputs, the output module projects the hidden features to the desired output dimension. In more detail, the core components of our model are illustrated in the following:

Graph Learning Layer

The graph learning layer learns a graph adjacency matrix adaptively to capture the hidden relationships among time series data. To construct a graph, existing studies measure the similarity between pairs of nodes by a distance metric, such as dot product and Euclidean distance [2]. This leads inevitably to the problem of high time and space complexity with $O(N^2)$. It means the computation and memory cost grows quadratically with the increase of graph size. This restricts the model's capability of handling larger graphs. To address this limitation, we adopt a sampling approach, which only calculates pair-wise relationships among a subset of nodes. This cuts off the bottleneck of computation and memory in each minibatch.

Another problem is that existing distance metrics are often symmetric or bi-directional. In multivariate time series forecasting, we expect that the change of a node's condition causes the change of another node's condition such as traffic flow. Therefore, the learned relation is supposed to be uni-directional. Our proposed graph learning layer is specifically designed to extract uni-directional relationships, illustrated as follows:

$$M_1 = \tanh(\alpha E_1 \Theta_1) \tag{1}$$

$$M_2 = \tanh(\alpha E_2 \Theta_2) \tag{2}$$

$$A = \text{ReLU}(\tanh(\alpha(M_1 M_2^T - M_2 M_1^T))) \tag{3}$$

$$\text{for } i = 1, 2, \dots, N \tag{4}$$

$$\text{idx} = \text{argtopk}(A[i, :]) \tag{5}$$

$$A[i, -\text{idx}] = 0, \tag{6}$$

where E_1, E_2 represents randomly initialized node embeddings, which are learnable during training, Θ_1, Θ_2 are model parameters, α is a hyper-parameter for controlling the saturation rate of the activation function, and $\text{argtopk}(\cdot)$ returns the index of the top-k largest values of a vector. The asymmetric property of our proposed graph adjacency matrix is achieved by Equation 3. The subtraction term and the ReLU activation function regularize the adjacency matrix so that if A_{vu} is positive, its diagonal counterpart A_{uv} will be zero. Equation 5-6 is a strategy to make the adjacency matrix sparse while reducing the computation cost of the following graph convolution. For each node, we select its top-k closest nodes as its neighbors. While retaining the weights for connected nodes, we set the weights of non-connected nodes as zero.

Incorporate External Data. The inputs to the graph learning layer are not limited to node embeddings. In case that external knowledge about the attributes of each node is given, we can also set $E_1 = E_2 = Z$, where Z is a static node feature matrix. Some works have considered capturing dynamic spatial dependencies [3]. In other words, they dynamically adjust the weight of two connected nodes based on temporal inputs. However, assuming dynamic spatial dependencies makes the model extremely hard to converge when we need to learn the graph structure at the same time. The advantage of our approach is that we can learn stable and interpretable node relationships over the period of the training dataset. Once the model is trained in an on-line learning version, our graph adjacency matrix is also adaptable to change as new training data updates the model parameters.

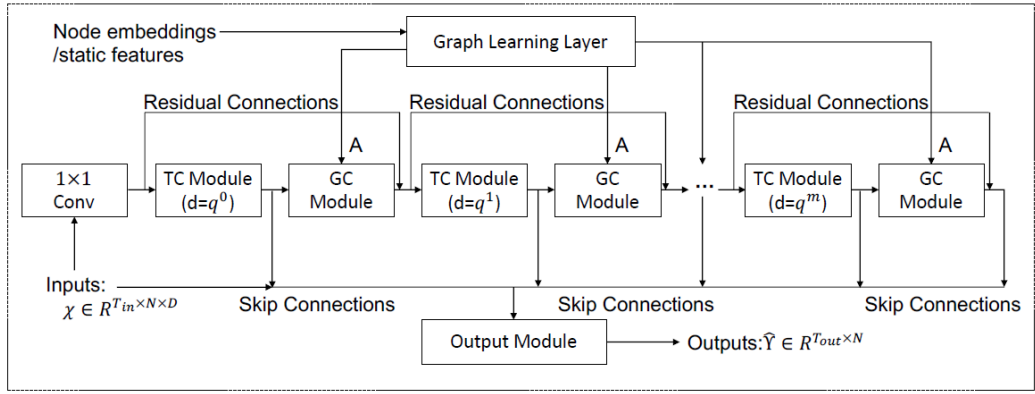


Figure 1 — The framework of MTGNN. A 1×1 standard convolution first projects the inputs into a latent space. Afterward, temporal convolution modules and graph convolution modules are interleaved with each other to capture temporal and spatial dependencies respectively. The hyper-parameter, dilation factor d , which controls the receptive field size of a temporal convolution module, is increased at an exponential rate of q . The graph learning layer learns the hidden graph adjacency matrix, which is used by graph convolution modules. Residual connections and skip connections are added to the model to avoid the problem of gradient vanishing. The output module projects hidden features to the desired dimension to get the final results.




Figure 2 — A demonstration of how a temporal convolution module and a graph convolution module collaborate with each other. A temporal convolution module filters the inputs by sliding a 1D window over the time and node axes, as denoted by the red. A graph convolution module filters the inputs at each step, denoted by the blue.

Graph Convolution Module

The graph convolution module aims to fuse a node's information with its neighbors' information to handle spatial dependencies in a graph. The graph

convolution module consists of two mixhop propagation layers to process inflow and outflow information passed through each node separately. The net inflow information is obtained by adding the outputs of the two mix-hop propagation layers. Figure 3 shows the architecture of the graph convolution module and the mix-hop propagation layer.

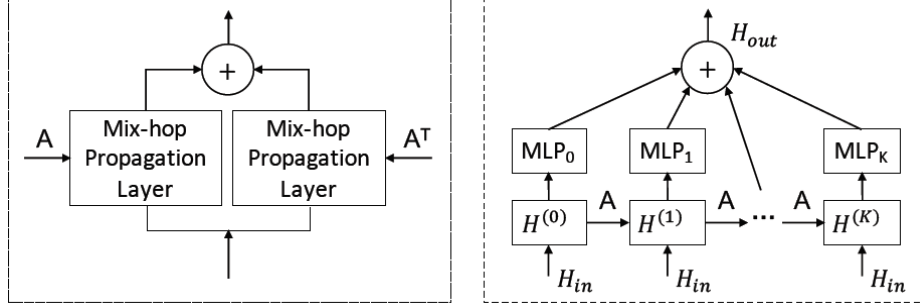


Figure 3 — Graph convolution and mix-hop propagation layer. (a — GC module, b — Mix-hop propagation layer)

Mix-hop Propagation Layer. Given a graph adjacency matrix, we propose the mix-hop propagation layer to handle information flow over spatially dependent nodes. The proposed mix-hop propagation layer consists of two steps - the information propagation step and the information selection step. We first give the mathematical form of these two steps and then illustrate our motivations. The information propagation step is defined as follows:

$$H^{(k)} = \beta H_{in} + (1 - \beta) \tilde{A} H^{(k-1)} \quad (7)$$

where β is a hyper parameter, which controls the ratio of retaining the root node's original states. The information selection step is defined as follows

$$H_{out} = \sum_{i=0}^K H^{(i)} W^{(i)} \quad (8)$$

where K is the depth of propagation, H_{in} represents the input hidden states outputted by the previous layer, H_{out} represents the output hidden states of the current layer, $H^{(0)} = H_{in}$, $\tilde{A} = \tilde{D}^{-1}(A + I)$, and $\tilde{D}_{ii} = 1 + \sum A_{ij}$. In Figure 3b, we demonstrate the information propagation step and information selection step in the

proposed mix-hop propagation layer. It first propagates information horizontally and selects information vertically.

The information propagation step propagates node information along with the given graph structure recursively. A severe limitation of graph convolutional networks is that node hidden states converge to a single point as the number of graph convolution layers goes to infinity. This is because the graph convolutional network with many layers reaches the random walk’s limit distribution regardless of the initial node states. To address this problem, motivated by Klicpera et al., we retain a proportion of nodes’ original states during the propagation process so that the propagated node states can both preserve locality and explore a deep neighborhood. However, if we only apply Equation 7, some node information will be lost. Under the extreme circumstance that no spatial dependencies exist, aggregating neighborhood information simply adds useless noises to each node. Therefore, the information selection step is introduced to filter out important information produced at each hop. According to Equation 8, the parameter matrix $W(k)$ functions as a feature selector. When the given graph structure does not entail spatial dependencies, Equation 8 is still able to preserve the original node-self information by adjusting $W^{(k)}$ to 0 for all $k > 0$.

Connection to existing works. The idea of mix-hop has been explored by [1]. Kapoor et al. [1] concatenate information from different hops. Chen et al. However, as GCN faces the oversmoothing problem, information from higher hops may not or negatively contribute to the overall performance. To avoid this, our approach keeps a balance between local and neighborhood information. Furthermore, Kapoor et al. [1] show that their proposed model with two mix-hop layers has the capability to represent the delta difference between two consecutive hops. Our approach can achieve the same effect with only one mix-hop propagation layer. Suppose $K = 2$, $W^{(0)} = 0$, $W^{(1)} = -1$, and $W^{(2)} = 1$, then

$$H_{\text{out}} = \Delta(H^{(2)}, H^{(1)}) = H^2 - H^1$$

9)

From this perspective, using summation is more efficient to represent all linear interactions of different hops compared with the concatenation method.




Figure 4: The temporal convolution and dilated inception layer. (a — TC module, b — Dilated inception layer)

Temporal Convolution Module

The temporal convolution module applies a set of standard dilated 1D convolution filters to extract high-level temporal features. This module consists of two dilated inception layers. One dilated inception layer is followed by a tangent hyperbolic activation function and works as a filter. The other layer is followed by a sigmoid activation function and functions as a gate to control the amount of information that the filter can pass to the next module. Figure 4 shows the architecture of the temporal convolution module and the dilated inception layer.

Dilated Inception Layer. The temporal convolution module captures sequential patterns of time series data through 1D convolutional filters. To come up with a temporal convolution module that is able to both discover temporal patterns with various ranges and handle very long sequences, we propose the dilated inception layer which combines two widely applied strategies from convolutional neural networks, i.e., using filters with multiple sizes [4] and applying dilated convolution [7].

First, choosing the right kernel size is a challenging problem for convolutional networks. The filter size can be too large to represent short-term signal patterns subtly, or too small to discover long-term signal patterns sufficiently. In image processing, a widely employed strategy is called inception,

which concatenates the outputs of 2D convolution filters with three different kernel sizes, 1×1 , 3×3 , and 5×5 . Moving from 2D images to 1D time series, the set of 1×1 , 1×3 , and 1×5 filter sizes do not suit the nature of temporal signals. As temporal signals tend to have several inherent periods such as 7, 12, 24, 28, and 60, a stack of inception layers with filter size 1×1 , 1×3 , and 1×5 cannot well encompass those periods. Alternatively, we propose a temporal inception layer consisting of four filter sizes, viz. 1×2 , 1×3 , 1×6 , and 1×7 . The aforementioned periods can all be covered by the combination of these filter sizes. For example, to represent the period 12, a model can pass the inputs through a 1×7 filter from the first temporal inception layer followed by a 1×6 filter from the second temporal inception layer.

Second, the receptive field size of a convolutional network grows in a linear progression with the depth of the network and the kernel size of the filter. Consider a convolutional network with m 1D convolution layers of kernel size c , the receptive field size of the convolutional network is,

$$R = m(c - 1) + 1 \tag{10}$$

To process very long sequences, it requires either a very deep network or very large filters. We adopt dilated convolution to reduce model complexity. Dilated convolution operates a standard convolution filter on down-sampled inputs with a certain frequency. For example, where the dilation factor is 2, it applies standard convolution on inputs sampled every two steps. Following, we let the dilation factor for each layer increase exponentially at a rate of q ($q > 1$). Suppose the initial dilation factor is 1, the receptive field size of an m layer dilated convolutional network with kernel size c is

$$R = 1 + (c - 1)(q^m - 1)/(q - 1) \tag{11}$$

This indicates that the receptive field size of the network also grows exponentially with an increase in the number of hidden layers at the rate of q .

Therefore, using this dilation strategy can capture much longer sequences than proceeding without it.

Formally, combining inception and dilation, we propose the dilated inception layer, demonstrated by Figure 4b. Given a 1D sequence input $z \in \mathbb{R}^T$ and filters consisting of $f_{1 \times 2} \in \mathbb{R}^2$, $f_{1 \times 3} \in \mathbb{R}^3$, $f_{1 \times 6} \in \mathbb{R}^6$, and $f_{1 \times 7} \in \mathbb{R}^7$, our dilated inception layer takes the form,

$$z = \text{concat}(z \star f_{1 \times 2}, z \star f_{1 \times 3}, z \star f_{1 \times 6}, z \star f_{1 \times 7}) \quad (12)$$

where the outputs of the four filters are truncated to the same length according to the largest filter and concatenated across the channel dimension, and the dilated convolution denoted by $z \star f_{1 \times k}$ is defined as

$$z \star f_{1 \times k}(t) = \sum_{s=0}^{k-1} f_{1 \times k}(s)z(t - d \times s) \quad (13)$$

where d is the dilation factor.

Skip Connection Layer & Output Module

Skip connection layers are essentially $1 \times L_i$ standard convolutions where L_i is the sequence length of the inputs to the i th skip connection layer. It standardizes information that jumps to the output module to have the same sequence length 1. The output module consists of two 1×1 standard convolution layers, transforming the channel dimension of the inputs to the desired output dimension. In case we want to predict a certain future step only, the desired output dimension is 1. When we want to predict Q consecutive steps, the desired output dimension is Q .

Proposed Learning Algorithm

We propose a learning algorithm to enhance our model's capability of handling large graphs and stabilizing in a better local optimum. Training on a graph often requires storing all node intermediate states into memory. If a graph is large, it will face the problem of memory overflow. Most relevant to us, Chiang et

al. They apply a graph clustering algorithm to partition a graph into subgraphs and train a graph convolutional network on the partitioned sub-graphs. In our problem, it is not practical to cluster nodes based on their topological information because our model learns the latent graph structure at the same time. Alternatively, in each iteration, we randomly split the nodes into several groups and let the algorithm learn a sub-graph structure based on the sampled nodes. This gives each node the full possibilities of being assigned with another node in one group so that the similarity score between these two nodes can be computed and updated. As a side benefit, if we split the nodes into s groups, we can reduce the time and space complexity of our graph learning layer from $O(N^2)$ to $(N/s)^2$ in each iteration. After training, as all node embeddings are well-trained, a global graph can be constructed to fully utilize spatial relationships. Although it is computationally expensive, the adjacency matrix can be precomputed in parallel before making predictions.

The second consideration of our proposed algorithm is to facilitate our model stabilize in a better local optimum. In the task of multi-step forecasting, we observe that long-term predictions often achieve greater improvements than those in the short-term in terms of model performance. We believe the reason is that our model predicts multi-steps altogether, and long-term predictions produce a much higher loss than short-term predictions. As a result, to minimize the overall loss, the model focuses more on improving the accuracy of long-term predictions. To address this issue we propose a curriculum learning strategy for the multi-step forecasting task. The algorithm starts with solving the easiest problem, predicting the next one-step only. It is very advantageous for the model to find a good starting point. With the increase in iteration numbers, we increase the prediction length of the model gradually so that the model can learn the hard task step by step. Covering all this, our algorithm is given in Figure 6.

```

1: Input: The dataset  $O$ , node set  $V$ , the initialized MTGNN model  $f(\cdot)$ 
   with  $\Theta$ , learning rate  $\gamma$ , batch size  $b$ , step size  $s$ , split size  $m$  (default=1).
2: set  $iter = 1, r = 1$ 
3: repeat
4:   sample a batch ( $\mathcal{X} \in R^{b \times T \times N \times D}, \mathcal{Y} \in R^{b \times T' \times N}$ ) from  $O$ .
5:   random split the node set  $V$  into  $m$  groups,  $\cup_{i=1}^m V_i = V$ .
6:   if  $iter \% s == 0$  and  $r \leq T'$  then
7:      $r = r + 1$ 
8:   end if
9:   for  $i$  in  $1:m$  do
10:    compute  $\hat{\mathcal{Y}} = f(\mathcal{X}[:, :, id(V_i), :]; \Theta)$ 
11:    compute  $L = loss(\hat{\mathcal{Y}}[:, : r, :], \mathcal{Y}[:, : r, id(V_i)])$ 
12:    compute the stochastic gradient of  $\Theta$  according to  $L$ .
13:    update model parameters  $\Theta$  according to their gradients and
       the learning rate  $\gamma$ .
14:   end for
15:    $iter = iter + 1$ .
16: until convergence

```

Figure 6 — Algorithm of MTGNN learning

Baseline Methods for Comparison

MTGNN and MTGNN+sampling are our models to be evaluated. MTGNN is our proposed model. MTGNN+sampling is our proposed model trained on a sampled subset of a graph in each iteration. Baseline methods are summarized in the following:

Single-step forecasting.

- AR: An auto-regressive model.
- VAR-MLP: A hybrid model of the multilayer perception (MLP) and auto-regressive model (VAR).
- GP: A Gaussian Process time series model.
- RNN-GRU: A recurrent neural network with fully connected GRU hidden units.
- LSTNet: A deep neural network, which combines convolutional neural networks and recurrent neural networks.

- TPA-LSTM: An attention-recurrent neural network.

Multi-step forecasting.

- DCRNN: A diffusion convolutional recurrent neural network, which combines diffusion graph convolutions with recurrent neural networks [2].
- STGCN: A spatial-temporal graph convolutional network, which incorporates graph convolutions with 1D convolutions [6].
- Graph WaveNet: A spatial-temporal graph convolutional network, which integrates diffusion graph convolutions with 1D dilated convolutions [5].
- ST-MetaNet: A sequence-to-sequence architecture, which employs meta networks to generate parameters.
- GMAN: A graph multi-attention network with spatial and temporal attentions.
- MRA-BGCN: A multi-range attentive bicomponent GCN.

Main Results

We observe that MTGNN achieves state-of-the-art results on most of the tasks, and the performance of MTGNN only degrades marginal when it samples sub-graphs for training. In the following, we discuss experimental results of single-step and multi-step forecasting respectively.

Single-step forecasting. In this experiment, we compare MTGNN with other multivariate time series models. In general, our MTGNN achieves state-of-the-art results over almost all horizons on Solar-Energy, Traffic, and Electricity data. In particular, on Traffic data, the improvement of MTGNN in terms of RSE is significant. MTGNN lowers down RSE by 7.24%, 3.88%, 4.83% over the horizons of 3, 12, 24 on the traffic data. The main reason why MTGNN improves the results of traffic data evidently is that the nature of traffic data is better suited for our model assumption about the spatial-temporal dependencies. Obviously, the future traffic occupancy rate of a road not only depends on its past but also on its connected roads' occupancy rates. MTGNN fails to make improvements on the

exchange-rate data, possibly due to the smaller graph size and fewer training examples of exchange-rate data.

Multi-step forecasting. In this experiment, we compare MTGNN with other spatial-temporal graph neural network models. The significance of MTGNN lies in that it achieves on-par performance with state-of-the-art spatial-temporal graph neural networks without using a pre-defined graph, while DCRNN, STGCN, and MRA-BGCN fully rely on pre-defined graphs. Graph Wavenet proposes a self-adaptive adjacency matrix, but it needs to combine with a pre-defined graph in order to achieve optimal performance. ST-MetaNet employs attention mechanisms to adjust the edge weights of a pre-defined graph. GMAN leverages node2vec algorithm to preserve node structural information while performing attention mechanisms. When a graph is not defined, these methods cannot model multivariate times series data efficiently.

Study of the Graph Learning Layer

To validate the effectiveness of our proposed graph learning layer, we conduct a study which experiments with different ways of constructing a graph adjacency matrix. Table 1 shows different forms of A with experimental results tested on the validation set of the METR-LA data averaged on 10 runs. Predefined-A is constructed by road network distance [2]. Global-A assumes the adjacency matrix is a parameter matrix, which contains N^2 parameters. Motivated by [5], Undirected-A and Directed-A are computed by the similarity scores of node embeddings. Motivated by [3], Dynamic-A assumes the spatial dependency at each time step is dependent on its node inputs. Uni-directed-A is our proposed method. According to Table 1, our proposed uni-directed-A achieves the lowest mean MAE, RMSE, and MAPE. It improves over predefined-A, undirected-A, and dynamic-A significantly. Our uni-directed-A improves over undirected-A and directed-A marginally in terms of MAE and MAPE but proves to be more robust due to a lower RMSE. We further investigate the learned graph adjacency matrix via a case study. In Figure 7a, we plot the raw time series of node 55 and its pre-

defined top-3 neighbors. In Figure 7b, we chart the raw time series of node 55 and its learned top-3 neighbors. Figure 7c shows the geo-location of these nodes, with green nodes representing the central node's learned top-3 neighbors and yellow nodes representing the central node's pre-defined top-3 neighbors. We observe that the central node's pre-defined top-3 neighbors are much closer to the node itself on the map. As a result, their time series are more correlated simultaneously, as shown by the red circles in Figure 6a. On the contrary, the central node's learned top-3 neighbors distribute further away from it but still lie on the same road it follows. According to Figure 7b, time series of the learned top-3 neighbors are more capable of indicating extreme traffic conditions of the central node in advance.



Figure 7: Case study (a — Time series of node 55 and its top-3 neighbors given by the pre-defined A, b — Time series of node 55 and its top-3 neighbors given by the learned A, c — Node locations of node 55 and its neighbors marked on Google Maps. Yellow nodes represent node 55’s top-3 neighbors given by the pre-defined A. Green nodes represent node 55’s top-3 neighbors given by the learned A.)

Table 1: Comparison of different graph learning methods.

Methods	Equation	MAE	RMSE	MAPE
Pre-defined-A	-	2.9017±0.0078	6.1288±0.0345	0.0836±0.0009
Global-A	$A = ReLU(W)$	2.8457±0.0107	5.9900±0.0390	0.0805±0.0009
Undirected-A	$A = ReLU(tanh(\alpha(M_1 M_1^T)))$	2.7736±0.0185	5.8411±0.0523	0.0783±0.0012
Directed-A	$A = ReLU(tanh(\alpha(M_1 M_2^T)))$	2.7758±0.0088	5.8217±0.0451	0.0783±0.0006
Dynamic-A	$A_t = SoftMax(tanh(X_t W_1) \wedge tanh(W_2^T X_t^T))$	2.8124±0.0102	5.9189±0.0281	0.0794±0.0008
Uni-directed-A (ours)	$A = ReLU(tanh(\alpha(M_1 M_2^T - M_2 M_1^T)))$	2.7715±0.0119	5.8070±0.0512	0.0778±0.0009

REFERENCES

1. Amol Kapoor, Aram Galstyan, Bryan Perozzi, Greg Ver Steeg, Hrayr Harutyunyan, Kristina Lerman, Nazanin Alipourfard, and Sami Abu-El-Haija. 2019. MixHop: Higher-Order Graph Convolutional Architectures via Sparsified Neighborhood Mixing. In Proc. of ICML.
2. Bing Yu, Haoteng Yin, and Zhanxing Zhu. 2018. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. In Proc. of IJCAI. 3634–3640.
3. Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. 2015. Going deeper with convolutions. In Proc. of CVPR. 1–9.
4. Fisher Yu and Vladlen Koltun. 2016. Multi-scale context aggregation by dilated convolutions. In ICLR.
5. Lei Shi, Yifan Zhang, Jian Cheng, and Hanqing Lu. 2019. Two-Stream Adaptive Graph Convolutional Networks for Skeleton-Based Action Recognition. In Proc. of CVPR. 12026–12035.
6. Yaguang Li, Rose Yu, Cyrus Shahabi, and Yan Liu. 2018. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. In Proc. of ICLR.
7. Zonghan Wu, Shirui Pan, Guodong Long, Jing Jiang, and Chengqi Zhang. 2019. Graph WaveNet for Deep Spatial-Temporal Graph Modeling. In Proc. of IJCAI.

1. Weiqi Chen, Ling Chen, *, Yu Xie, Wei Cao, Yusong Gao, Xiaojie Feng 2018. Spatio-Temporal Graph Convolutional Networks: A Deep Learning Framework for Traffic Forecasting. In Proc. of IJCAI. 3634–3640.
2. Fisher Yu and Vladlen Koltun. 2016. Multi-scale context aggregation by dilated convolutions. In ICLR.