

Тема работы: «Развитие моделей турбулентности с помощью методов машинного обучения для течений в каналах»

Состав коллектива:

Токарев Михаил Петрович, mtokarev@itp.nsc.ru, к.т.н., с.н.с. ИТ СО РАН, рук. проекта РНФ №22-19-00587 (доступ на кластер НГУ пока не нужен)

Яковенко Сергей Николаевич, д.ф.-м.н., доцент, в.н.с. ИТПМ СО РАН, отв. исп. проекта РНФ №22-19-00587 – snyakovenko (учетная запись на кластере НГУ)

Ли Хаоянь, russianmlhy@mail.ru, магистрант НГУ, исп. проекта РНФ №22-19-00587

Информация о гранте:

Работа поддержана грантом РНФ №22-19-00587 “Создание эффективных численных моделей для описания турбулентного течения теплоносителя при низких числах Прандтля на основе методов машинного обучения, детальных экспериментальных данных и результатов вихререзающего моделирования”, 2022-2024, руководитель – Токарев Михаил Петрович.

Аннотация

Целью данной работы является использование методов машинного обучения: программирования экспрессии генов (GEP) для создания явной модели тензора напряжений Рейнольдса для течений в каналах. Проведены предварительные оценки и тестовые расчеты для канонического турбулентного течения в канале с периодическими холмами при помощи открытого пакета OpenFOAM.

Априорные оценки показывают, что использование GEP приводит к уточнению распределений для компонент тензора анизотропии напряжений Рейнольдса по сравнению с их аналогами, вычисленными по базовой линейной модели вихревой вязкости. Результаты подстановки моделей для напряжений Рейнольдса в осредненные уравнения Навье – Стокса

показывают, что методы GEP позволяют уточнить распределения турбулентной кинетической энергии, компонент вектора средней скорости.

Постановка задачи. Применяются различные методы машинного обучения (в частности, нейронная сеть с тензорным базисом, программирование экспрессии генов) для аппроксимации напряжений Рейнольдса в канонических течениях в двумерных каналах с поперечными и продольными выступами различной формы, в каналах квадратного сечения, для которых доступны высокоточные данные прямого численного моделирования (DNS), моделирования крупных вихрей (LES), используемые для обучения и калибровки моделей.

Современное состояние проблемы, с ссылками на источники, предпочтительно доступные в сети Интернет:

Анализ существующих подходов и сопутствующих проблем численной реализации и адекватного представления данных показывает, что создание эффективного инструмента для моделирования турбулентных течений в сложных практических задачах все еще остается нерешенной актуальной проблемой. В обзорных работах отмечается, что RANS-модели из-за ограничений и высокой стоимости вихререзающих подходов будут оставаться в ближайшие десятилетия популярным инструментом в научных и инженерных расчетах. Однако, эти модели оказываются менее точными и неуниверсальными, нуждаясь в улучшении на основе имеющихся данных измерений и вихререзающего моделирования. Недавно появилось новое направление, основанное на привлечении в дополнение к физическим соображениям методов машинного обучения (machine learning, ML) для разработки улучшенных моделей турбулентности и их калибровки на больших массивах данных высокоточных методов (DNS, LES, измерения). ML-технологии позволяют построить отображения между данными высокоточных методов и приближенных моделей, минимизировать

отклонения между ними и найти оптимальную форму коррекций модели. В частности, предложена новая архитектура [1], включающая нейронную сеть с тензорным базисом (TBNN) со встроенными свойствами инвариантности для определения коэффициентов функциональной зависимости между тензором напряжений Рейнольдса и конечным набором функций симметричной и антисимметричной частей тензора градиента средней скорости. В [2] для уточнения явных алгебраических моделей турбулентных напряжений использована символьная регрессия и программирование экспрессии генов (GEP). В [3] рассмотрены ограничения и недостатки методов TBNN, GEP и предложены усовершенствованные подходы. В этих и других недавних работах в качестве базовых использованы одно- и двухпараметрические модели турбулентности и рассмотрен большой набор канонических тестовых течений (течения в каналах с плоскими и неровными стенками, обтекание препятствий, следы, струи) для обучения моделей.

Список литературы:

[1] Ling J., Kurzawski A., Templeton J. Reynolds averaged turbulence modelling using deep neural networks with embedded invariance // J. Fluid Mech. 2016. Vol. 807. P. 155–166.

[2] Weatheritt J., Sandberg R. A novel evolutionary algorithm applied to algebraic modifications of the RANS stress–strain relationship // J. Comput. Phys. 2016. Vol. 325. P. 22–37.

[3] Jiang C., Vinuesa R., Chen R., Mi J., Laima S., Li H. An interpretable framework of data-driven turbulence modeling using deep neural networks // Phys. Fluids. 2021. Vol. 33. # 055133.

Подробное описание работы, включая используемые алгоритмы.

Программирование экспрессии генов (GEP, gene expression programming) является эволюционным алгоритмом, реализации которого позволяют выполнить символьную регрессию скалярных и тензорных полей, а также кластеризацию наборов данных. Метод (GEP) использует линейную цепочку генов для представления решения. Гены в цепочке кодируют математические выражения, а алгоритм эволюционирует эти выражения на протяжении нескольких поколений, чтобы найти лучшее решение для данной проблемы. GEP используют в различных приложениях, включая обработку данных, обработку изображений, финансовое прогнозирование.

Регрессию тензорных полей можно использовать для построения нелинейных соотношений напряжения-деформации для замыкания RANS уравнений. При этом линейная модель LEVM для напряжений Рейнольдса дополняется членом, учитывающим анизотропию t_{ij} . Этот член, полученный регрессией на основе данных DNS, приводит к явной нелинейной алгебраической модели.

Для развития алгебраической модели напряжений Рейнольдса, алгоритм MGEP реализуется через следующие шаги:

1. Определяются коэффициенты каждой генетической операции, выбирается функция приспособленности для оценки потомства, устанавливается размер популяции, длина головки гена, количество генов в одной хромосоме и одной плазмиде, а также количество поколений (итераций).
2. Случайным образом генерируется начальная популяция хромосом для первого поколения.
3. Вычисляется приспособленность каждого индивидуума, и выбираются те, которые соответствуют заданным критериям. Кроме того, отдельно сохраняется наилучший индивидуум.
4. Применяются генетические операции (например, скрещивание и мутация) к выбранным хромосомам, исключая лучшую хромосому.
5. Собираются плазмиды из хромосом, которые прошли генетические операции.
6. Генетические операции применяются к собранным плазмидам, которые распределяются обратно в хромосомы.
7. Генерируется новое поколение, использующее выбранные хромосомы и лучшую хромосому из предыдущего поколения. Повторяются шаги с 3 по 7 до достижения заданного количества поколений.

Полученные результаты.

На кластере не удобно настроить гипер-параметры алгоритма MGEP, так что мы перестал использовать его для своей научной работы после некоторых попыток. Поэтому не получили соответствующие результаты через кластер.