

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ РОССИЙСКОЙ ФЕДЕРАЦИИ
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ТОМСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
АНГАРСКИЙ ГОСУДАРСТВЕННЫЙ ТЕХНИЧЕСКИЙ УНИВЕРСИТЕТ
ИНСТИТУТ ВЫЧИСЛИТЕЛЬНОЙ МАТЕМАТИКИ И МАТЕМАТИЧЕСКОЙ ГЕОФИЗИКИ СО РАН

**НОВЫЕ ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ
В ИССЛЕДОВАНИИ
СЛОЖНЫХ СТРУКТУР**

**МАТЕРИАЛЫ
ТРИНАДЦАТОЙ МЕЖДУНАРОДНОЙ КОНФЕРЕНЦИИ
7–9 сентября 2020 г.**

Томск
Издательский Дом Томского государственного университета
2020

The modification consists in separating the control commands (forward, left, right) from the signals to the servo motor and to the engine. The control commands are formed by the neural network based on the images received from the camera. The signals to the servo motor and to the engine are formed by a simple program, according to the classification results received from the neural network. The second modification is to reduce the number of fully connected layers and add a Dropout layer.

To train the network, 25,000 images were used. The training process was performed on a stationary computer equipped with an Intel i5-4570 processor, 20GB RAM, and a GeForce GTX 750 Ti graphics card. The training lasted 40 minutes. After training, the network was uploaded to the Raspberry Pi 3B, and the car automatically moved along the track at a speed of 1m / s. The accuracy of choosing the direction of movement, in this case, can be obtained at least 92%.

Literature

1. Self-driving car. Available at: https://en.wikipedia.org/wiki/Self-driving_car, accessed 30.05.2019.
2. A Full Hardware Guide to Deep Learning. Available at: <https://timdettmers.com/2018/12/16/deep-learning-hardware-guide>, accessed 15.12.2019.
3. Raspberry Pi 3 Model B. Available at: <https://www.raspberrypi.org/products/raspberry-pi-3-model-b/>, accessed 29.05.2019.
4. End-to-End Deep Learning for Self-Driving Cars. Available at: <https://devblogs.nvidia.com/deep-learning-self-driving-cars/>, accessed 20.03.2017.
5. Keras: The Python Deep Learning library. Available at: <https://keras.io/>, accessed 15.01.2019.

СИСТЕМА АВТОМАТИЗАЦИИ ТРАССИРОВКИ ПЕЧАТНЫХ ПЛАТ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ

А.Д. Брагина^{1,2}, М.Л. Громов²

¹ АО «Информационные спутниковые системы» имени академика М.Ф. Решетнева», Железногорск, Россия

² Национальный исследовательский Томский государственный университет, Томск, Россия
alina_bragina_tomsk@mail.ru

Трассировка печатных плат – одна из ключевых ступеней в производстве и изготовлении приборов и аппаратуры. Для того чтобы снизить трудозатраты, а также сократить время на проектирование печатных плат необходимо автоматизировать процесс трассировки.

Современные САПР, такие как Altium Designer, TopoR, SPECCTRA и PCAD имеют функцию автоматической трассировки, однако не во всех случаях существует возможность её применения. Автоматическая трассировка имеет минимальные огрехи только в тех проектах, в которых компоновка изделий РЭА не плотная. С увеличением плотности компоновки происходит усложнение процесса трассировки, так как увеличивается количество конфликтных ситуаций. Печатные платы, топология которых спроектирована автоматической программой трассировки, всегда уступают печатным платам, спроектированным опытным разработчиком по количеству ошибок в конечной трассировке, длине проводников, оптимальных решений конфликтных ситуаций. Важным аспектом автоматической трассировки является корректировка получившейся топологии в ручном режиме. Зачастую, данная корректировка требует внушительных изменений в топологии разрабатываемой печатной платы, что неоправданно увеличивает время, необходимое для её разработки.

Основные проблемы, с которыми сталкивается разработчик при автоматизированном проектировании топологии печатных плат следующие:

1. Более длинные проводники.
2. Неоптимальное решение конфликтных ситуаций в топологии.
3. Необходимость перепроверки и коррекции получившейся трассировки.
4. Невозможность трассировки печатных проводников группами (шинами).

Таким образом, решение проблемы автоматической трассировки печатных плат, которое исключило бы хотя бы один из вышеуказанных недостатков, является актуальной задачей. Оно значительно сократило бы как требуемое вмешательство инженера в уже оттрассированную плату, так и время подготовки платы к производству. Для поиска этого решения в данной работе предполагается применить технологии искусственных нейронных сетей.

На данный момент, в различных источниках проблематично найти какие-либо упоминания об использовании нейронных сетей при автоматизации трассировки печатных плат, из чего можно сделать вывод, что данная проблема либо не рассматривалась, либо только начинает попадать в область зрения различных ученых.

Учитывая вышесказанное, предлагается следующая концепция: на основании исходных данных – электрической принципиальной схемы, моделей электронных компонентов, а также расположения элементов на печатной плате, будет формироваться файл изображения. На данном изображении будут отображены

границы печатной платы, а также контактные площадки электронных компонентов. Нейронные сети сгенерируют новое изображение с дорожками, соединяющими соответствующие контактные площадки.

Входными данными для обучения нейронных сетей будут являться изображения. В качестве алгоритмов обучения нейронных сетей с подкреплением (в англоязычной литературе – Reinforcement Learning) будут использоваться метод Монте-Карло и алгоритм Q-обучения. Метод Монте-Карло заключается в следующем: процесс описывается математической моделью с использованием генератора случайных величин, модель многократно обчисляется, на основе полученных данных вычисляются вероятностные характеристики рассматриваемого процесса. Алгоритм Q-обучения имеет немного иной принцип действия: на основе получаемого от среды вознаграждения агент формирует некоторую функцию полезности Q, что в последствии дает ему возможность уже не случайно выбирать стратегию поведения, а учитывать опыт предыдущего взаимодействия со средой. На основании полученных выходных данных (изображений с топологией) и некоторой качественной функции, будет проведен сравнительный анализ применяемых алгоритмов, выявлены их преимущества и недостатки.

Литература

1. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение / пер. с англ. А.А. Слинкина. 2-е изд., испр. М.: ДМК Пресс, 2018. С. 35.
2. Алексеева И.Ю., Никитина Е.А. Интеллект и технологии. М: Проспект, 2016. С. 74–76.
3. Хайкин Саймон. Нейронные сети: полный курс. 2-е изд. / пер. с англ. М. : Вильямс, 2006. С. 31–36.
4. Уваров А.С. Проектирование печатных плат. 8 лучших программ: М.: ДМК Пресс, 2009. С. 181, 195, 237.

ОПРЕДЕЛЕНИЕ ТЕМПЕРАТУРЫ И ПАРЦИАЛЬНЫХ ДАВЛЕНИЙ КОМПОНЕНТОВ ВЫСОКОТЕМПЕРАТУРНОЙ ГАЗОВОЙ СМЕСИ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ*

Д.Е. Каширский

Национальный исследовательский Томский государственный университет, Томск, Россия
kde@mail.tsu.ru, majitova.meerimai@gmail.com

Оптические измерения активно используются для определения концентраций компонентов газовых сред природного и антропогенного происхождения [1–4]. Каждый газ обладает индивидуальным спектром поглощения, что позволяет идентифицировать газ в составе газовой смеси. Основным преимуществом оптических методов является возможность дистанционного анализа газового состава. Данная работа является продолжением [5], где рассматривался случай определения температуры и парциального давления одного газа.

В отличие от [5], в данной работе решается обратная задача оптики газовых сред для случая четырехкомпонентной (H_2O , CO_2 , CO и NO) газовой среды. Вычисление пропускания газовой смеси осуществлялось методом line-by-line на выбранных из спектрального интервала $1000–2500\text{ см}^{-1}$ двадцати центрах для спектрального разрешения 1 см^{-1} , используя базу данных HITRAN2010 [6]. Температура смеси изменялась в интервале $800–1800\text{ К}$, а парциальное давление каждого из компонентов – $0.1–0.7\text{ атм}$. Эти условия приближены к экспериментальным, при которых проводились измерения спектров пропускания газов H_2O и CO_2 в [7].

По аналогии с [5] для решения обратной задачи оптики газовых сред использовалась полносвязная искусственная нейронная сеть (ИНС) – многослойный персептрон [8]. На вход ИНС подавались значения коэффициентов пропускания для рассматриваемых спектральных центров. На выходе ИНС получались искомые величины – температура и парциальные давления четырех рассматриваемых газов. Количество скрытых слоев и нейронов в них было различным и варьировалось от 2 до 4 и от 10 до 25 соответственно. Обучение ИНС проводилось с помощью градиентного алгоритма оптимизации первого порядка Adam [9] на трех обучающих выборках с разным количеством примеров для обучения. Программная реализация осуществлена на языке Python с применением библиотек TensorFlow [10] и Keras [11].

Проведено исследование зависимости максимальной относительной ошибки определения искомых параметров от размера обучающей выборки и конфигурации ИНС. Показана возможность решения обратной задачи оптики газовых сред по определению температуры и парциальных давлений газов в случае четырехкомпонентной газовой смеси с помощью ИНС с максимальной относительной ошибкой в пределах 5 %.

Литература

5. Bacsik Z., Mink J., Keresztury G. FTIR Spectroscopy of the Atmosphere Part 2. Applications // Applied Spectroscopy Reviews. 2005. Vol. 40. P. 327–390.

* Данное научное исследование выполнено при финансовой поддержке стипендией Президента Российской Федерации (СП-3875.2018.5)