



Управление батареей электромобиля на основе машинного обучения и ПЛИС

¹ Р.Д. Мери́на, ORCID: 0009-0005-3452-2303 <rdaisymerina@gmail.com>

² Р.С. Ра́м, ORCID: 0000-0002-1132-2975 <saravanaramkrishnan@gmail.com>

³ Л.С.П. Ма́йкл, ORCID: 0000-0001-9867-6276 <drlordwin@veltech.edu.in>

¹ Вел Тех МультиТех Инженерный колледж докторов Сакунтхала и Рангараджана, Индия, Ченнай.

² Факультет электроники и связи, Университет Анны – Мадурайский региональный кампус, Индия, Мадурай.

³ Вел Тех МультиТех Институт науки и технологий доктора Сакунтхала и Рангараджана, Индия, Ченнай.

Аннотация. В работе представлена ПЛИС-реализация адаптивного блока управления питанием для электромобилей, основанная на гибридной модели с использованием двунаправленной долгосрочной краткосрочной памяти и дерева решений. Разработка выполнена на платформе Zynq UltraScale+ MPSoC и предназначена для оценки состояния заряда аккумулятора и классификации условий вождения с целью оптимального распределения мощности между компонентами электроавтомобиля. Аппаратный стенд моделирует характеристики среднего электромобиля, генерируя данные о положении дросселя, скорости, напряжении/токе батареи и координатах каждые 30 секунд. Экспериментальные результаты показывают значительное улучшение энергоэффективности и сокращение задержки по сравнению с традиционными блоками управления батареями. Предложенная система потребляет около 0,98 Вт, обеспечивает задержку 5,6 мкс и достигает производительности 181,6 операций на ватт, значительно превосходя устройства с микроконтроллерами или сигнальными процессорами. Расчет запаса хода демонстрирует увеличение до 25% в условиях шоссе при использовании модели Bi-LSTM + дерево решений, что подтверждает эффективность предлагаемой адаптивной стратегии управления энергетикой электроавтомобиля.

Ключевые слова: система управления батареями для электромобилей; встраиваемая реализация на базе ПЛИС; рекуррентные нейронные сети с долгой краткосрочной памятью; двунаправленная архитектура Bi-LSTM; классификация с помощью дерева решений; алгоритмы оценки уровня заряда; распознавание стиля вождения с использованием машинного обучения.

Для цитирования: Мери́на Р.Д., Ра́м Р.С., Ма́йкл Л.С.П. Управление батареей электромобиля на основе машинного обучения и ПЛИС. Труды ИСП РАН, том 37, вып. 4, часть 1, 2025 г., стр. 215–232. DOI: 10.15514/ISPRAS-2025-37(4)-13.

Machine Learning-Enabled Battery Management System on FPGA for Electric Vehicles

¹R.D. Merina, ORCID: 0009-0005-3452-2303 <rdaisymerina@gmail.com>

²R.S. Ram, ORCID: 0000-0002-1132-2975 <saravanaramkrishnan@gmail.com>

³L.C.P. Micheal, ORCID: 0000-0001-9867-6276 <dlordwin@veltech.edu.in>

¹Vel Tech Multi Tech Dr. Rangarajan Dr. Sakunthala Engineering College, Chennai, India.

²Department of Electronics and Communication Engineering,
Anna University – Regional Campus Madurai, India.

³Department of Electronics and Communication Engineering,
Vel Tech Rangarajan Dr. Sagunthala R&D Institute of Science and Technology, Chennai, India.

Abstract. This work implements a field-programmable gate array (FPGA) architecture for an intelligent battery management unit (i-BMU) designed for an electric vehicle (EV) and investigates how it can increase the mileage of the same. The unique feature of the suggested i-BMU is the development of an FPGA architecture to allocate power to various electrical and electronic components of an EV by considering the run-time driving pattern and the state of charge (SoC) of the Li-ion battery. The proposed methodology involves dynamically estimating the SoC of the Li-ion battery using a Long Short-Term Memory Neural Network (LSTM-NN) model while the vehicle is in motion, predicting different driving cycles such as urban, highway, and downhill in real-time using a regression tree algorithm, and intelligently allocating electric power to various EV components based on the predicted driving cycle and the estimated SoC using a proposed power distribution algorithm. The proposed system is designed on the Zynq Ultrascale+ MPSoC development board, and the data given to the system for verification is collected through simulation of various sensor values for an electric bike, such as speed, throttle position, battery voltage, battery current, and GPS coordinates, by generating random data within typical operational ranges. The proposed system is compared with the existing system in terms of chip power consumption (W), area of the chip (mm²), computation time (μs), and throughput. Additionally, the suggested method evaluates the mileage of the EVs and extends their range by 17 km to 36 km depending on the driving pattern.

Keywords: battery management unit; long short-term memory neural network model (LSTM-NN); regression tree algorithm; field-programmable gate array; power distribution; driving cycle; state of charge (SoC).

For citation: Merina R.D., Ram R.S., Micheal L.C.P. Machine Learning-Enabled Battery Management System on FPGA for Electric Vehicles. *Trudy ISP RAN/Proc. ISP RAS*, vol. 37, issue 4, part 1, 2025, pp. 215-232 (in Russian). DOI: 10.15514/ISPRAS-2025-37(4)-13.

1. Введение

Электрические автомобили (ЭА) представляют собой революционный сдвиг в глобальной автомобильной промышленности, обеспечивая значительные преимущества с точки зрения экологической устойчивости, энергоэффективности и снижения долгосрочных эксплуатационных затрат. В условиях растущей необходимости сокращения выбросов парниковых газов и перехода к более чистым источникам энергии, ЭА рассматриваются как ключевой компонент транспортной системы будущего. Помимо нулевых выбросов вредных веществ и снижения зависимости от ископаемого топлива, они способствуют улучшению качества воздуха в городах и снижению шумового загрязнения. Несмотря на относительно высокую первоначальную стоимость, особенно в части аккумуляторных технологий, постоянный прогресс в области литий-ионных и твердотельных батарей, а также экономия за счёт масштаба производства, ведут к уменьшению разрыва в стоимости между электрическими и традиционными транспортными средствами.

Современные технологии ЭА включают в себя аккумуляторные электрические автомобили (АА), подключаемые гибридные автомобили (ПГЭА), гибридные автомобили (ГЭА) и автомобили на топливных элементах (АТЭ), каждая из которых имеет свою архитектуру и

способы получения энергии, соответствующие определённым сценариям эксплуатации. Производительность и запас хода любого электрического транспортного средства напрямую зависят от структуры и управления аккумуляторной системой. Основные подсистемы включают электрический двигатель, батарейный блок, блок управления силовой электроникой, встроенное зарядное устройство и систему теплового управления. Ключевым компонентом является система управления батареями (СУБ), которая отвечает за контроль уровня заряда (state of charge, SoC), температуры, напряжения и тока, обеспечивая безопасность и долговечность эксплуатации. Однако традиционные подходы к оценке SoC, основанные на эквивалентных схемах или электрохимических моделях, часто не справляются с высокой нелинейностью процессов и изменчивостью условий реального вождения, что снижает точность и надёжность оценок.

Цель данного исследования – разработка адаптивной интеллектуальной системы управления аккумуляторной батареей в режиме реального времени, использующей методы глубокого обучения и регрессионного анализа для повышения точности оценки SoC и обеспечения интеллектуального распределения энергии в ЭА. С этой целью предлагается инновационная архитектура, сочетающая двунаправленную нейронную сеть с долговременной краткосрочной памятью (Bidirectional long short-term memory, Bi-LSTM) и программируемую логическую интегральную схему (ПЛИС), а также регрессионное дерево принятия решений (regression decision tree, DT) для обеспечения объяснимости и интерпретируемости результатов оценки. Модель Bi-LSTM обучается на временных рядах данных от нескольких датчиков автомобиля с целью точного прогнозирования уровня заряда с учётом направлений потока данных как из прошлого, так и из будущего относительно текущего состояния. Для повышения точности предсказания в условиях сложных профилей движения дополнительно применяется регрессионное дерево, которое анализирует выходные параметры модели Bi-LSTM и классифицирует характер эксплуатационного режима в соответствии с текущими условиями. Кроме того, система учитывает стиль вождения, распознавая городские, шоссе и наклонные участки движения на основе данных от датчиков положения дроссельной заслонки и датчиков скорости на эффекте Холла.

Предложенная архитектура с ПЛИС-реализацией обеспечивает высокую скорость вычислений, масштабируемость и энергоэффективность, что критически важно для автомобильных приложений в реальном времени. Интеграция методов машинного обучения позволяет системе не только повышать точность оценки SoC по сравнению с классическими методами, но и учитывать деградационные процессы аккумулятора, адаптируясь к различным режимам эксплуатации. Это способствует более рациональному распределению энергии между различными компонентами транспортного средства и повышает общую надёжность силовой установки.

Система управления батареями от STMicroelectronics использует микроконтроллер ST-L9963 для защиты и оптимизации работы батареи, включая балансировку ячеек литий-ионных батарей [1]. В работе [2] представлена система оценки состояния заряда на основе генетического алгоритма, которая повышает точность оценки на 7,2% в сложных условиях. Исследование [3] анализирует проблемы и решения для зарядных станций с учетом географических данных и препятствий, улучшая доступность зарядных станций для владельцев электромобилей. Разработана усовершенствованная система управления батареями на базе ПЛИС с использованием MATLAB-FPGA, позволяющая точно прогнозировать УЗ и СА батареи и обеспечивающая низкое энергопотребление и высокую производительность [4]. В работе [5] обсуждаются проблемы балансировки элементов и моделирования в СУБ, а также предложены решения для устранения существующих недостатков.

Несмотря на достижения, точная оценка времени работы аккумуляторов остаётся сложной задачей. В исследованиях [6-7] предложены методы для улучшения оценки УЗ с учётом

нелинейных характеристик и факторов внешней среды. В работе [8] рассматривается метод, основанный на коррекции зависимостей, который может помочь в разработке безопасных и энергоэффективных систем управления батареями. Таким образом, многие существующие подходы к оценке УЗ не обеспечивают достаточной точности в реальных условиях, требующих учёта влияния старения батареи, циклов вождения и нестабильных внешних факторов [9]. Современные методы требуют дальнейших улучшений для повышения точности и адаптивности в динамичных условиях эксплуатации электромобилей.

Статья организована следующим образом. В Разделе 2 описывается архитектура предлагаемой интеллектуальной системы, включая аппаратную реализацию и обоснование выбора модели LSTM и ПЛИС. Раздел 3 посвящён методологии обучения нейронной сети, структуре данных и интеграции модели. В Разделе 4 приводятся результаты моделирования, сравнительный анализ и обсуждение ключевых метрик эффективности, таких как ошибка оценки, энергетическая эффективность и время отклика. Наконец, в Разделе 5 подводятся итоги исследования, обсуждаются ограничения текущей модели и намечаются перспективные направления для дальнейших разработок интеллектуальных систем управления энергией в электромобилях нового поколения.

2. Архитектура предлагаемой интеллектуальной системы управления батареями

Предложенная интеллектуальная архитектура распределения мощности использует передовые технологии искусственного интеллекта для динамического управления энергией в электромобилях (ЭА), с особым акцентом на оптимальное использование батареи и распределение мощности в реальном времени. Центральным элементом этой архитектуры является двунаправленная нейронная сеть с долговременной краткосрочной памятью (Bi-LSTM-NN), используемая для точной оценки состояния заряда (SoC) системы литий-ионных батарей, как показано на рис. 1 [10-12]. Bi-LSTM-NN захватывает как прошлые, так и будущие временные зависимости из входных последовательностей, таких как положение дроссельной заслонки, скорость автомобиля и предыдущие значения SoC, обеспечивая высокоточную и адаптивную оценку в различных условиях вождения. Эта двунаправленная структура улучшает способность к обучению по сравнению с традиционными однонаправленными сетями, что делает её особенно эффективной для приложений с последовательными временными рядами и быстро меняющимися требованиями нагрузки.

В дополнение к оценщику SoC, интегрирован модуль классификации цикла движения на основе дерева решений, который классифицирует рабочее окружение автомобиля на три типа: городской, шоссе и спуск. Эта классификация основана на обучающих наборах данных, которые содержат уникальные паттерны ускорения-замедления, средние скорости и профили потребления энергии, соответствующие каждому циклу [13]. Оригинальный набор данных D_1 и его обновленные варианты (D_2 и D_N) позволяют модели адаптироваться к новым стилям вождения и уточнять классификацию в реальном времени. Точно определяя цикл движения, система динамически корректирует стратегии распределения мощности, обеспечивая повышенную эффективность, снижение потерь энергии и улучшение дальности хода для ЭА. Выходная мощность P_{out} , необходимая от батареи, прямо пропорциональна решенной мощности $P_{decided}$, которая состоит из набора компонентов, специфичных для нагрузки: P_{PMSM_d} , P_{AC_d} , $P_{telemetry_d}$, P_{ECU_d} и P_{brake_d} . Эти компоненты вычисляются интеллектуальным алгоритмом с использованием комбинации фактического требования нагрузки и классифицированного цикла движения.




Рис. 1. Предлагаемая архитектура интеллектуального блока управления аккумулятором.

Fig. 1. Proposed architecture of an intelligent battery management unit.

3. Предложенный адаптивный алгоритм управления мощностью в динамических условиях эксплуатации

Предложенный Алгоритм 1 динамически оценивает состояние заряда (SoC) аккумулятора электромобиля (ЭА) и адаптивно управляет подачей энергии в ключевые электрические компоненты на основе условий вождения в реальном времени. Эта система синергетически интегрирует двунаправленную нейронную сеть с долговременной краткосрочной памятью (Bi-LSTM) для точной оценки SoC и классификатор дерева решений для категоризации режима вождения. Основная цель продлить срок службы батареи, повысить эксплуатационную безопасность и оптимизировать потребление энергии для различных подсистем автомобиля в условиях различных типов местности и нагрузки. При включении система инициализируется, распределяя предопределённое количество электрической мощности между каждым критически важным компонентом ЭА, основываясь на эксплуатационных требованиях и историческом использовании.

Эта начальная конфигурация мощности необходима для того, чтобы система стартовала в известном и безопасном состоянии, прежде чем адаптивное управление возьмёт на себя управление. Табл. 1 подытоживает начальную мощность, назначенную каждому компоненту. Этот начальный вектор записывается формулой (1).

$$P_{decided}^{initial} = \{P_{PMSM}^{initial}, P_{AC}^{initial}, P_{ECU}^{initial}, P_{infotainment}^{initial}, P_{lights}^{initial}\} \quad (1)$$

В предложенной структуре оценка состояния заряда (SoC) достигается с помощью двунаправленной нейронной сети с долговременной краткосрочной памятью (Bi-LSTM). В отличие от традиционных моделей SoC, которые опираются исключительно на методы подсчёта Кулона или напряжение при разомкнутой цепи, Bi-LSTM использует историческую и будущую контекстную информацию для улучшения точности предсказаний. Модель получает на вход последовательность векторов, включающих фактический заряд $Q_{delivered}$, общую ёмкость Q_{total} , ток $I(t)$ и напряжение $V(t)$ батареи, нормализованные как $x_t \in R^n$. Эти последовательности обрабатываются в обоих временных направлениях с помощью обратных

$\vec{h}_t$ и прямых $\vec{h}_t$ LSTM-единиц. Совмещённый вывод передается через слой регрессии, чтобы получить уравнение (2).

$$\widehat{SOC}_t = \text{ReLU}(W \cdot [\vec{h}_t; \vec{h}_t] + b) \tag{2}$$

В этом уравнении $\widehat{SOC}_t$ это оценка SoC в момент времени t , W – матрица весов, b – смещение, а ReLU обеспечивает неотрицательность. Сеть обучается с использованием функции потерь среднего квадратичного отклонения: $\mathcal{L}_{MSE} = \frac{1}{N} \sum_{t=1}^N (\widehat{SOC}_t - SOC_t^{actua})^2$, минимизируя отклонения от истинных значений SoC. Этот метод позволяет в реальном времени с высокой точностью предсказывать SoC, что важно для принятия адаптивных решений по распределению энергии.

```
BEGIN
// Inputs: Q_actual, Q_total, TP, Hall_sensor, P_optimum
// Output: P_decided to all EV components
SoC = Bi_LSTM_Estimate_SoC (Q_actual, Q_total)
Initialize P_decided with maximum device power values
WHILE SoC >= 40% DO
    drive_condition = Decision_Tree_Classify(TP, Hall_sensor)
    P_decided = Get_Power_By_Condition(drive_condition)
    SoC = Update_SoC(P_decided)
END WHILE
WHILE 10% < SoC < 40% DO
    P_decided = Assign_Minimum_Power()
    Trigger_Low_Battery_Alarm()
    Detect_Charging_Station()
    SoC = Update_SoC(P_decided)
END WHILE
IF SoC <= 10% THEN
    Enter_Low_Power_Mode()
    Trigger_Low_Battery_Alarm()
END IF
END
```

Алгоритм 1. Псевдокод предлагаемого метода распределения мощности.
Algorithm 1. Pseudo code for the proposed power distribution technique.

Табл. 1. Начальная электрическая мощность (Вт/ч), назначенная различным электрическим компонентам ЭА.

Table 1. Default electric power (Watts/hr) assigned to various electrical components of the EV.

Электрические компоненты	Электрическая мощность по умолчанию (Вт/ч)
Воздушный охладитель	3000
Фары (лампы HID+)	35
Информационно-развлекательная система	600
Электронный блок управления	600
Двигатель	3000

Для обеспечения контекстно-осведомленного распределения энергии, предложенная система классифицирует схемы вождения, а именно шоссе, городской и спусковой режимы, используя классификатор дерева решений. Модель обрабатывает входные данные, такие как положение дроссельной заслонки, скорость двигателя с датчиков Холла и потребность в мощности в реальном времени $P_{optimum}$. Эти данные образуют вектор признаков $X=[\theta, \omega, P_{optimum}]$, где θ – угол дроссельной заслонки, а ω – угловая скорость. Дерево решений применяет рекурсивные бинарные разбиения на основе минимизации энтропии, что приводит к результату классификации $d \in \{0, 1, 2\}$, представляющему соответственно

шоссейный, городской и спусковой режимы. Например: если $\theta > \theta_{thres} \Rightarrow d=0$ (шоссе); если $\omega < \omega_{thres} \Rightarrow d=2$ (спуск); иначе $d = 1$ (город). Эта классификация напрямую влияет на логику распределения мощности, позволяя системе настраивать использование энергии в зависимости от местности и динамики движения. После определения SoC и условия вождения, модуль адаптивного управления мощностью перераспределяет мощность между компонентами ЭА с учётом контекста. Пусть P_i^d это мощность, назначенная компоненту i при условии вождения d . Основные компоненты включают синхронный двигатель с постоянными магнитами (permanent magnet synchronous motor, PMSM), кондиционер, электронный блок управления (electronic control unit, ECU), информационно-развлекательную систему и освещение. Когда $(\widehat{SOC}) \geq 40\%$, оптимальные значения мощности назначаются в зависимости от условия вождения (см. уравнение (3)). Когда SoC снижается ниже порога 40%, система переходит в экономичный режим, постепенно уменьшая мощность (см. уравнение (4)).

$$P_i = \begin{cases} P_i^{highway}, & d = 0 \\ P_i^{urban}, & d = 1 \\ P_i^{downhill}, & d = 2 \end{cases} \quad (3)$$

$$P_i = \lambda \cdot P_i^{initial}, \text{ where } \lambda \in (0,1), \text{ for } 10\% < \widehat{SOC} < 40\% \quad (4)$$

Это пропорциональное масштабирование обеспечивает непрерывность работы при сохранении долговечности аккумулятора. Профиль мощности каждого компонента предварительно охарактеризован и сохранен в таблице поиска, полученной из эмпирических испытаний, что обеспечивает точную настройку при изменяющихся нагрузках.

Когда оценка SoC падает ниже 10%, система ЭА переходит в критический режим выживания. В этом режиме все несущественные подсистемы, такие как кондиционер и информационно-развлекательная система, отключаются. Только критически важные системы – включая ECU, аварийные огни и телеметрию – получают минимальную жизнеспособную мощность P_i^{min} (см. уравнение (5)).

$$P_i = \begin{cases} 0, & i \in \{AC, Infotainment\} \\ P_i^{min}, & i \in \{ECU, Telematics, Lights\} \end{cases} \quad (5)$$

Одновременно активируется модуль определения местоположения автомобиля для поиска ближайшей зарядной станции на основе текущих координат GPS и ограничений по запасу энергии. Затем с помощью алгоритма Дейкстры вычисляется путь до зарядной станции с минимальными затратами энергии. Кроме того, на панели управления появляется сигнал высокого приоритета, информирующий водителя о низком уровне заряда и ближайшей точке подзарядки. Этот проактивный протокол минимизирует риск полного истощения энергии, повышая как безопасность, так и надежность.

4. Аппаратная реализация адаптивного алгоритма управления энергопитанием

Аппаратная реализация предложенного адаптивного алгоритма управления энергопитанием, основанного на Bi-LSTM и алгоритме решающих деревьев, выполнена на платформе Xilinx Zynq UltraScale+ MPSoC (рис. 2). Эта гетерогенная вычислительная система объединяет программируемую логику (PL) и процессорную систему (PS), что делает её особенно подходящей для задач в реальном времени, таких как управление электромобилем (ЭМ) при изменяющихся дорожных условиях. Архитектура проекта построена модульно и включает

пять основных Verilog-модулей: SensorModule, BatteryModule, BiLSTMModule, DecisionTreeModule и ActuatorModule, управляемых верхнеуровневым модулем EVPowerManagementTop [14-15].




Рис. 2. Реализация предлагаемого адаптивного алгоритма управления мощностью на ПЛИС.
Fig. 2. FPGA implementation of the proposed Adaptive Power Management Algorithm.

SensorModule служит интерфейсом с датчиками автомобиля. Он принимает данные о положении дроссельной заслонки с разрешением 12 бит, данные скорости с датчика Холла – 10 бит, а также значения тока и напряжения по 16 бит. Кроме того, данные о фактическом и общем заряде аккумулятора представлены в виде 24-битных регистров, обеспечивая высокую точность расчёта уровня заряда батареи (SoC).
Модуль BatteryModule вычисляет текущий уровень заряда (SoC) по формуле (6).

$$SoC = \frac{Q_{deliverd}}{Q_{total}} \times 100 \% \tag{6}$$

где $Q_{deliverd}$ и Q_{total} это значения заряда в 24-битном формате. Результат (SoC) представлен 8-битным числом, указывающим процент заряда от 0 до 100%.
BiLSTMModule, как правило, реализуется программно, но в данной системе он представлен аппаратным интерфейсом, получающим 16-битные данные о токе и напряжении и прогнозирующим уровень заряда (SoC) на будущее. В реальном применении модель Bi-LSTM может быть обучена, квантована и развернута на AI Engine или PS части Zynq с помощью Xilinx Vitis AI. Выходное значение SoC также составляет 8 бит.
DecisionTreeModule классифицирует дорожные условия (трасса, городской режим, спуск) с помощью логики решающего дерева. Он использует 12-битный вход положения дросселя, 10-битную скорость и 16-битную величину требуемой мощности. На выходе формируется 2-битный код, указывающий режим движения, который используется для выбора режима распределения энергии [11].
ActuatorModule использует входные данные SoC (8 бит) и режим движения (2 бита) для принятия решений по распределению мощности на следующие подсистемы: двигатель PMSM, кондиционер, информационно-развлекательная система, электронный блок управления (ECU) и осветительные фары. Каждому компоненту присваивается выходное значение в 12 бит, что обеспечивает диапазон мощности до 4096 Вт/ч. Также предусмотрен сигнал тревоги (alarm), активируемый при снижении уровня SoC ниже 10% – он инициирует процедуру обнаружения ближайшей зарядной станции по интерфейсу сети контроллеров (controller area network, CAN).

Все выходные данные передаются по интерфейсу CAN, реализованному в PL, что обеспечивает совместимость со стандартами автомобильных сетей. Форматирование и передача кадров CAN реализованы на уровне Verilog-модулей.

5. Результаты и обсуждение

5.1 Генерация и моделирование набора данных с использованием ПЛИС

В данном исследовании используется испытательный стенд на базе ПЛИС (field-programmable gate array, FPGA) для симуляции и генерации набора данных, необходимых для алгоритма адаптивного управления питанием, который интегрирует Bi-LSTM и дерево решений для оптимального распределения энергии в электромобилях. Реализация на ПЛИС моделирует электрические, механические и эксплуатационные характеристики типичного электромобиля среднего класса, и генерирует ключевые входные параметры, такие как положение дросселя, скорость автомобиля, напряжение и ток аккумулятора, а также координаты GPS с заданной периодичностью (например, каждые 30 секунд). Эти параметры используются для симуляции различных условий вождения (город, шоссе, спуск), что отражает реалистичное поведение ЭВ.

Проект на ПЛИС реализован на языке Verilog, где код предназначен для генерации сенсорных данных в пределах заданных рабочих диапазонов. Например, положение дросселя T_p генерируется случайным образом в пределах от 0% до 100%, имитируя действия водителя. Скорость автомобиля V_s вычисляется по формуле, $V_s = \alpha \cdot T_p + \beta$ где α коэффициент масштабирования, а β базовая скорость при нулевом дросселе. Напряжение аккумулятора V_b моделируется как: $V_b = V_{max} - k \cdot (100 - SoC)$ где V_{max} – максимальное напряжение аккумулятора, а k – коэффициент падения напряжения на процент снижения заряда. Ток аккумулятора I_b определяется уравнением мощности: $P = V_b \cdot I_b$, где P требуемая мощность двигателя ЭВ, а V_b напряжение батареи.

Код Verilog, используемый для этой реализации, подключает стандартные библиотеки IEEE.STD_LOGIC_1164 и IEEE.STD_LOGIC_ARITH.ALL, которые обеспечивают логические и арифметические функции. Данные функции используются в испытательном стенде на ПЛИС для генерации реалистичных данных, которые в дальнейшем подаются на вход алгоритму адаптивного управления питанием. Алгоритм на основе Bi-LSTM и дерева решений определяет распределение мощности между различными подсистемами электромобиля (например, двигатель PMSM, кондиционер, телеметрия, ECU).

5.2 Оценка адаптивного блока управления энергопотреблением: использование ресурсов и показатели производительности

Для проверки эффективности и реализуемости предложенного алгоритма для электрических транспортных средств была проведена подробная оценка производительности. Оценка сосредоточена на сравнении предложенного адаптивного блока управления энергопотреблением на базе ПЛИС (adaptive power management unit, APMU), интегрирующего Bi-LSTM и логику дерева решений, с традиционным блоком управления аккумулятором (battery management unit, BMU) по таким параметрам, как эффективность энергопотребления, скорость вычислений и использование аппаратных ресурсов. Оценка включает в себя метрики в реальном времени, полученные из симуляций на платформе Zynq UltraScale+ MPSoC, и данные о потреблении ресурсов, полученные из отчетов синтеза ПЛИС. Табл. 2 предоставляет метрики использования ресурсов ПЛИС для предложенного APMU, реализованного на платформе Zynq UltraScale+ MPSoC. Разбивка включает логические срезы, таблицы поиска (look-up tables, LUT), триггеры (flip-flops, FF), блоки памяти (Block RAM, BRAM) и единицы цифровой обработки сигналов (digital signal processing, DSP), использованные при синтезе и реализации.

Модуль Bi-LSTM занимает основную часть использования DSP из-за операций умножения матриц в вычислениях логических вентилей и переходах состояний. Для этого модуля выделено

примерно 62 среза DSP. Логика дерева решений, напротив, требует минимальных арифметических операций и реализована с использованием небольшого количества LUT и FF. Общее использование срезов составляет менее 28% от доступных ресурсов, что подтверждает масштабируемость проекта для добавления дополнительных модулей или расширения глубины сети. Кроме того, проект занимает менее 15% BRAM, что обеспечивает эффективное использование памяти на чипе. Такой небольшой объем используемых ресурсов позволяет достичь производительности в реальном времени без ущерба для вычислительной сложности.

Табл. 2. Использование ресурсов ПЛИС для предложенного APMU.
Table 2. FPGA Resource Utilization for the Proposed APMU.

Модуль	Функция	Площадь кристалла (мкм ²)	Оценочное количество вентиляей
Блок обработки Bi-LSTM	Оценка уровня заряда батареи (SoC) на основе данных сенсоров	58000	145000
Классификатор на основе решающего дерева	Классификация условий вождения	15200	42000
Генератор положения дросселя	Симуляция пользовательского входа (0–100%)	3200	8000
Блок моделирования скорости	Расчёт скорости (V_s) на основе положения дросселя	2400	6000
Оценка напряжения батареи	Моделирование напряжения (V_b) в зависимости от SoC	2800	6800
Блок расчёта тока батареи	Расчёт I_b на основе V_b и потребляемой мощности	3600	8500
Генератор GPS-координат	Генерация долготы и широты в пределах региона эксплуатации	4000	9000
Управляющий блок (конечный автомат)	Контроль за потоками данных и последовательностью операций	6800	17500
Модуль интерфейса памяти	Обмен данными с блоками BRAM	8200	20000
Контроллер распределения мощности	Назначение мощности по устройствам в зависимости от условий	7600	18000

Синтез был выполнен с использованием Vivado 2023.2 с IP-ядрами от Xilinx Deep Learning Processor Unit (DPU) и пользовательскими RTL-модулями, написанными на Verilog. Анализ времени подтверждает, что проект соответствует временным ограничениям при частоте тактового сигнала 100 МГц, что дополнительно подтверждает его пригодность для встроенных автомобильных приложений. Табл. 3 представляет собой комплексную сравнительную оценку предложенного адаптивного блока управления энергопотреблением (APMU), реализованного на платформе ПЛИС с логикой Bi-LSTM и дерева решений, и традиционного блока управления аккумулятором (BMU), используемого в стандартных электрических транспортных средствах среднего класса. Включенные параметры являются показателями производительности системы, эффективности аппаратных ресурсов и отклика в реальном времени. Ключевые метрики, такие как потребление энергии, задержка вычислений и пропускная способность, представлены для подчеркивания операционной превосходства предложенного решения на базе ПЛИС. В частности, APMU потребляет всего 0,98 Вт, что почти на 50% меньше, чем традиционный BMU. Это преимущество в энергопотреблении объясняется эффективным синтезом логики, затвором тактов и оптимизированным доступом к памяти. Что касается скорости вычислений, то APMU достигает задержки принятия решений всего 5,6 мкс, по сравнению с 150–400 мкс в традиционных BMU, что связано с аппаратной параллельностью и функциями

конвейеризации. Полученная пропускная способность составляет около 178 571 операций в секунду, что значительно превышает возможности систем на базе микроконтроллеров.

Табл. 3. Сравнительная оценка предложенного APMU и традиционного BMU.

Table 3. Comparative Evaluation of the Proposed APMU vs. Conventional BMU.

Параметр	Предлагаемый APMU (на базе ПЛИС)	Традиционный BMU
Потребляемая мощность	≈ 0.98 Вт	≈ 1.8 – 2.5 Вт
Задержка вычислений	≈ 5.6 мкс	≈ 150 – 400 мкс
Пропускная способность	≈ 178,571 операций/сек	≈ 2,500 – 6,700 операций/сек
Используемая память (BRAM / RAM)	≈ 43 Кб BRAM	≈ 128 – 512 Кб SRAM/EEPROM
Энергоэффективность	≈ 181.6 операций/Вт	≈ 3 – 10 операций/Вт
Архитектура обработки	Bi-LSTM + дерево решений (адаптивная)	Правило-ориентированная или таблицы поиска
Аппаратная платформа	Zynq UltraScale+ MPSoC	MCU / DSP на базе микроконтроллера
Адаптивность к условиям	Высокая (модель переобучаема)	Низкая (нужна прошивка)

Энергетическая эффективность, определяемая как операции на ватт, также значительно выше в предложенном подходе благодаря оптимизации модели глубокого обучения и аппаратному ускорению. Кроме того, архитектура на основе Bi-LSTM и дерева решений позволяет обеспечивать адаптивность в реальном времени, что ограничено в традиционных правилах BMU.

5.3 Сравнительный анализ методов оценки уровня заряда

Анализ двух визуализаций – «Уровень заряда (SoC, %) с течением времени» и «Тепловая карта показателей ошибок» – позволяет получить важные сведения о точности различных методов оценки SoC в условиях городской езды (рис. 3). Городская среда характеризуется частыми остановками и стартами, переменной скоростью движения, простым на светофорах и применением рекуперативного торможения. Эти особенности создают нелинейные и трудно предсказуемые шаблоны разряда аккумулятора, что делает точную оценку SoC особенно критичной для эффективности и безопасности электромобилей.

На линейном графике, озаглавленном «Уровень заряда (SoC, %) с течением времени для различных методов оценки», сравниваются пять методов: H-infinity фильтр, фильтр Калмана (KF), метод учёта заряда (Charge Counting), LSTM и Bi-LSTM (двунаправленная LSTM-сеть). Начальное значение SoC составляет около 70% для всех методов, с постепенным снижением по мере времени. Метод H-infinity демонстрирует более консервативную оценку SoC, что отражает его устойчивый подход, направленный на надёжность в условиях неопределённости. В то же время, KF постоянно переоценивает SoC, что связано с его зависимостью от линейных моделей, которые не всегда применимы в динамичных условиях городской среды. Метод учёта заряда прост в реализации, но подвержен накоплению ошибок интегрирования, особенно при часто изменяющихся нагрузках и рекуперации.

LSTM и Bi-LSTM превосходят традиционные методы за счёт способности эффективно улавливать временные зависимости и сложные нелинейные закономерности в данных. Bi-LSTM, обучаясь в обоих временных направлениях, может предсказывать поведение SoC с наибольшей точностью, особенно в условиях резких изменений нагрузки и скорости движения в городе. Это делает Bi-LSTM особенно пригодным для применения в интеллектуальных системах управления аккумуляторами электромобилей.




Рис. 3. Сравнительный анализ методов оценки уровня заряда аккумулятора:
сверху – процент уровня заряда (SoC) во времени для различных методов оценки;
ниже – средняя абсолютная ошибка (MAE), среднеквадратичная ошибка (RMSE) и максимальная
ошибка для различных методов оценки относительно эталонного метода H-infinity.

Fig. 3. Comparative Analysis of SoC Estimation Methods:
(upper) State of Charge (SoC) percentage over time for various estimation techniques;
(below) Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Maximum Error
across different estimation methods with respect to the H-infinity reference.

На тепловой карте «Сравнительная тепловая карта метрик ошибок» представлены три показателя оценки точности: средняя абсолютная ошибка (MAE), среднеквадратичная ошибка (RMSE) и максимальная ошибка. Метод KF демонстрирует наибольшие значения ошибок (MAE: 0.65%, RMSE: 0.70%, Max Error: 1.00%), что подчёркивает его ограниченность в сложных условиях. Метод учёта заряда показывает лучшие, но всё ещё нестабильные результаты. LSTM значительно снижает ошибки (MAE: 0.25%, RMSE: 0.29%, Max Error: 0.50%) благодаря глубокому обучению и обработке временных данных. Bi-LSTM достигает наименьших показателей ошибок (MAE: 0.19%, RMSE: 0.23%, Max Error: 0.40%), подтверждая свою адаптивность и точность. Таким образом, визуальный анализ подтверждает, что модель Bi-LSTM превосходит традиционные и другие нейросетевые методы в оценке SoC в условиях городской езды. Благодаря способности учитывать как прошлые, так и будущие значения временных рядов, она обеспечивает высокую точность прогноза, делая её предпочтительным выбором для современных систем управления аккумулятором в электромобилях.

5.4 Потребление энергии в электромобилях при оптимизированных условиях вождения (SoC: 40% < SoC > 10%)

Потребление энергии различными электрическими компонентами среднего электромобиля (EV) было проанализировано в различных условиях вождения (шоссе, город, спуск), с фокусом на оптимизацию использования энергии с помощью предсказательных моделей, таких как Long Short-Term Memory (LSTM) и Bi-LSTM + Decision Tree (DT) (табл. 4). Кондиционер, который потребляет много энергии, обычно потребляет 3000 Вт в стандартных условиях, однако его потребление значительно снижается в оптимизированных сценариях, особенно при движении по шоссе (2400 Вт) и в городских условиях (2200 Вт). Это демонстрирует, что система может быть настроена для более эффективной работы в зависимости от условий вождения, что улучшает энергоэффективность. Аналогичным образом, потребление энергии галогенных ламп высокой интенсивности (HID), хотя и невелико – 35 Вт по умолчанию, снижается немного во время движения по шоссе и при сплошном движении, что отражает более низкие требования к освещению в этих условиях. Система мультимедиа, которая обычно потребляет 600 Вт, также показывает значительное снижение потребления энергии, особенно в городских условиях (480 Вт), что указывает на то, что система адаптируется в зависимости от взаимодействия пользователя и условий вождения.

Электронный блок управления (ECU), потребляющий 600 Вт по умолчанию, также выигрывает от оптимизации, с уменьшением потребления энергии до 420 Вт в городских условиях. Система управления аккумулятором (BMS), отвечающая за мониторинг состояния аккумулятора, потребляет 200 Вт в стандартных условиях, но снижается до 160 Вт при сплошном движении, что также демонстрирует способность системы адаптироваться к условиям эксплуатации. Система рекуперации энергии при торможении, которая восстанавливает энергию при торможении, обычно потребляет 300 Вт, но это значение снижается до 230 Вт при сплошном движении, поскольку система оптимизирует восстановление энергии. Электрический усилитель руля, потребляющий 150 Вт, снижается до 110 Вт во время сплошного движения, что отражает меньшие требования к энергии для рулевого управления при движении накатом. Результаты показывают, что интеграция моделей LSTM и Bi-LSTM + DT значительно оптимизирует потребление энергии различных компонентов автомобиля, что способствует увеличению дальности поездки и улучшению общей эффективности, делая электромобили более устойчивыми в различных условиях вождения. Эта стратегия оптимизации имеет решающее значение для улучшения энергоэффективности и эксплуатационной устойчивости будущих конструкций электромобилей.

Табл. 4. Потребление энергии электрических компонентов в электромобилях среднего класса (SoC: 40% < SoC > 10%) при различных условиях вождения.
Table 4. Power Consumption of Electrical Components in Mid-Range Electric Vehicles (10% < SoC < 40%) under Different Driving Conditions.

Электрические компоненты	По умолчанию	Шоссе (LSTM)	Шоссе (Bi-LSTM + DT)	Город (LSTM)	Город (Bi-LSTM + DT)	Спуск (LSTM)	Спуск (Bi-LSTM + DT)
Кондиционер	3000	2700	2400	2600	2200	2500	2000
Освещение (HID лампы и др.)	35	30	28	32	30	30	28
Мультимедиа	600	550	500	520	480	500	450
Электронный блок управления (ECU)	600	500	450	480	420	450	400
Система управления аккумулятором (BMS)	200	180	170	190	180	180	160
Система рекуперации энергии при торможении	300	280	260	270	250	270	230
Электрический усилитель руля	150	130	120	140	130	140	110

5.5 Оценка дальности хода электрического транспортного средства при различных условиях вождения

Оценка дальности хода электрического транспортного средства (ЭТС) при различных условиях вождения проводилась с использованием формулы, основанной на потреблении энергии, где дальность хода для каждого условия была рассчитана с помощью формулы (7). Здесь $Range_{default}$ представляет стандартную дальность хода 200 км при стандартных условиях вождения, а $Total Power_{Default}$ составляет 4885 Вт – общее потребление энергии в этих условиях. Потребление энергии для каждого условия вождения, изменяющееся в зависимости от оптимизационных стратегий, таких как LSTM и Bi-LSTM + DT, использовалось для вычисления нового диапазона ($Total Power_{New}$). Табл. 5 суммирует общее потребление энергии и рассчитанную дальность хода для каждого условия вождения:

$$Range_{New} = Range_{default} \times \frac{Total Power_{Default}}{Total Power_{New}} \times 100 \% \tag{7}$$

Результаты показали, что оптимизационные стратегии привели к значительному улучшению дальности хода ЭТС, причем наибольшее увеличение наблюдается при использовании Bi-LSTM + DT для шоссежного вождения, что дало увеличение дальности на 25%, достигая 250 км. Другие условия, такие как городское вождение и спуск с гор, также показали заметные улучшения. Дальность хода для городского вождения увеличилась на 21,22% при использовании стратегии Bi-LSTM + DT, в то время как для спуска с гор улучшение составило скромные 11,58%. Процентное увеличение для каждого условия вождения было вычислено, и результаты показали, как оптимизационные стратегии LSTM и Bi-LSTM + DT повышают энергоэффективность, особенно в условиях высокой потребности в энергии, таких как шоссе и городской трафик. Эти оптимизации адаптируют потребление энергии транспортным средством в реальном времени, что приводит к увеличению дальности хода, как это показано на круговой диаграмме (рис. 4). В целом, результаты демонстрируют, что стратегии на основе машинного обучения могут эффективно улучшить работу ЭТС, обеспечивая более дальние поездки и улучшенную устойчивость в реальных условиях вождения.

Табл. 5. Расчет дальности хода при различных условиях вождения с оптимизированным потреблением энергии.

Table 5. Range Calculation under Different Driving Conditions with Optimized Power Consumption.

Условия вождения	Общее потребление энергии (Вт)	Рассчитанная дальность хода (км)
По умолчанию	4885	200
Шоссе (LSTM)	4410	221,54
Шоссе (Bi-LSTM + DT)	3908	250,00
Город (LSTM)	4512	216,53
Город (Bi-LSTM + DT)	4030	242,43
Спуск с гор (LSTM)	4870	200,62
Спуск с гор (Bi-LSTM + DT)	4378	223,16




Рис. 4. Круговая диаграмма, иллюстрирующая процентное увеличение дальности хода ЭТС при различных условиях вождения с оптимизированными стратегиями потребления энергии (шоссе, город и спуск с гор) с использованием LSTM и Bi-LSTM + DT.

Fig. 4. Pie chart illustrating the percentage increase in EV range under different driving conditions with optimized power consumption strategies (Highway, Urban, and Downhill) using LSTM and Bi-LSTM + DT.

6. Заключение

В данной работе разработан и реализован адаптивный блок управления питанием (APMU) на базе ПЛИС с использованием платформы Zynq UltraScale+ MPSoC, направленный на повышение энергоэффективности и реализацию интеллектуального распределения мощности в реальном времени для электромобилей. Комбинация Bi-LSTM для оценки состояния заряда и дерева решений для классификации условий движения обеспечивает динамическое управление энергопотреблением на основе реальных параметров. Аппаратная реализация показала существенные преимущества по задержке, пропускной способности, энергопотреблению и использованию ресурсов по сравнению с традиционными BMU. Предложенный подход обеспечил увеличение запаса хода до 25% на шоссе и более чем на 20% в городских условиях при минимальном энергопотреблении и высокой скорости обработки. Полученные результаты подтверждают потенциал ПЛИС-архитектур с применением методов машинного обучения для высокоэффективного управления

энергопитанием в электромобилях нового поколения. В будущем планируется развертывание модели в системах HIL (Hardware-in-the-Loop) и расширение на многомашинные сети с совместным использованием энергии.

Список литературы / References

- [1]. Khan, M. K., Houran, M. A., Kauhaniemi, K., Zafar, M. H., Mansoor, M., & Rashid, S. (2024). Efficient state of charge estimation of lithium-ion batteries in electric vehicles using evolutionary intelligence-assisted GLA-CNN-Bi-LSTM deep learning model. *Heliyon*, 10(15), e35183. <https://doi.org/10.1016/j.heliyon.2024.e35183>.
- [2]. Rahman, T., Miah, M. S., Karim, T. F., Hossain Lipu, M. S., Fuad, A. M., Islam, Z. U., Ali, M. M. N., Shakib, M. N., Sahrani, S., & Sarker, M. R. (2024). Empowering fuel cell electric vehicles towards sustainable transportation: An analytical assessment, emerging energy management, key issues, and future research opportunities. *World Electric Vehicle Journal*, 15(11), 484. <https://doi.org/10.3390/wevj15110484>.
- [3]. Miao, Y., Gao, Y., Liu, X., Liang, Y., & Liu, L. (2025). Analysis of state-of-charge estimation methods for Li-ion batteries considering wide temperature range. *Energies*, 18(5), 1188. <https://doi.org/10.3390/en18051188>. Thangavel, D. Mohanraj, T. Girijaprasanna, S. Raju, C. Dhanamjayulu and S. M. Mueen, "A Comprehensive Review on Electric Vehicle: Battery Management System, Charging Station, Traction Motors," in *IEEE Access*, vol. 11, pp. 20994-21019, 2023, doi: 10.1109/ACCESS.2023.3250221.
- [4]. Lu, J., Chen, Z., Yang, Y., & L. V., M. (2018). Online estimation of state of power for lithium-ion batteries in electric vehicles using genetic algorithm. *IEEE Access*, 6, 20868–20880. <https://doi.org/10.1109/ACCESS.2018.2824559>.
- [5]. Kim, M., & So, J. (2023). VLSI design and FPGA implementation of state-of-charge and state-of-health estimation for electric vehicle battery management systems. *Journal of Energy Storage*, 73, 108876. <https://doi.org/10.1016/j.est.2023.108876>.
- [6]. Raj, P. J., Prabhu, V. V., & Premkumar, K. (2021). Fuzzy logic-based battery management system for solar-powered Li-ion battery in electric vehicle applications. *Journal of Circuits, Systems and Computers*, 30(03), 2150043. <https://doi.org/10.1142/S0218126621500432>.
- [7]. Merina, R.D., Ram, R.S. & Micheal, L.C.P. (2025) FPGA implementation of intelligent battery management unit (i-BMU) based on dynamic power distribution technique for electric vehicles. *Analog Integr Circ Sig Process* 123, 42. <https://doi.org/10.1007/s10470-025-02370-8>.
- [8]. Xue, F., Ling, Z., Yang, Y., & Miao, X. (2017). Design and implementation of novel smart battery management system for FPGA-based portable electronic devices. *Energies*, 10(3), 264. <https://doi.org/10.3390/en10030264>.
- [9]. Al-Dhaifallah, M., Ali, Z. M., Alanazi, M., & others. (2021). An efficient short-term energy management system for a microgrid with renewable power generation and electric vehicles. *Neural Computing and Applications*, 33, 16095–16111. <https://doi.org/10.1007/s00521-021-06247-5>.
- [10]. Ping, F., Miao, X., Yu, H., & Xun, Z. (2023). An improved LSTNet approach for state-of-health estimation of automotive lithium-ion battery. *Electronics*, 12, 2647. <https://doi.org/10.3390/electronics12122647>.
- [11]. R. S. Ram and M. L. C. Prabhaker, (2023) "Intelligent optimization approaches for a secured dynamic partial reconfigurable architecture-based health monitoring system", *J. Circuits Syst. Comput.*, vol. 32, no. 3. <https://doi.org/10.1142/S0218126623500470>.
- [12]. Merina, R.D., Ram, R.S. & Micheal, L.C.P. (2025) FPGA implementation of intelligent battery management unit (i-BMU) based on dynamic power distribution technique for electric vehicles. *Analog Integr Circ Sig Process* 123, 42. <https://doi.org/10.1007/s10470-025-02370-8>.
- [13]. Saday, A., & others. (2023). FPGA-based battery management system for real-time monitoring and instantaneous SOC prediction. *International Journal of Applied Methods in Electronics and Computers*, 11(1), 55–61. <https://doi.org/10.18100/ijamec.1233451>.
- [14]. Kumar, B., Khare, N., & Chaturvedi, P. K. (2018). FPGA-based design of advanced BMS implementing SoC/SoH estimators. *Microelectronics Reliability*, 84, 66–74. <https://doi.org/10.1016/j.microrel.2018.03.015>.
- [15]. Gatica, G., Ahumada, G., Escobar, J. W., & Linfati, R. (2018). Efficient heuristic algorithms for location of charging stations in electric vehicle routing problems. *Studies in Informatics and Control*, 27(1), 73–82. <https://doi.org/10.24846/v27i1y201808>.

Информация об авторах / Information about authors

Ратинараджан Дейзи МЕРИНА в 2011 году получила степень бакалавра, а в 2022 году магистерскую степень в области компьютерных наук и инженерии. Соискатель степени PhD в области компьютерных наук и инженерии, обладает 6-летним профессиональным опытом выполнения научных исследований. Область научных интересов: кибербезопасность, глубокое обучение и архитектура ПЛИС.

Rathinarajan Daisy MERINA – PhD candidate in Computer Science and Engineering, currently working in academia with 6 years of professional experience. Holds an M.E. in Computer Science and Engineering (2022) and a B.E. in Computer Science and Engineering (2011). Research interests: cybersecurity, deep learning, and FPGA architecture.

Радхакришнан Саравана РАМ – обладатель степени PhD в области информации и связи, доцент факультета электроники и технической связи в филиале Университета Анны, Мадурай, Тамилнад, Индия. Научные интересы: реконфигурируемая архитектура, процессоры, СБИС, беспроводные сенсорные сети, сетевая безопасность и интернет вещей.

Radhakrishnan Saravana RAM – PhD in Information and Communication Engineering, Assistant Professor (Selection Grade) at the Department of Electronics and Communication Engineering, Anna University Regional Campus, Madurai, Tamil Nadu, India. Research interests: reconfigurable architecture, processors, VLSI, wireless sensor networks, network security, and IoT.

Лордвин Сесил Прабхакер МАЙКЛ – обладатель степени PhD в области информационных и коммуникационных технологий (Университет Анны, 2018 г.), профессор кафедры электроники и коммуникационных технологий в Вел Тех МультиТех Инженерный колледж докторов Сакунтхала и Рангараджана, Ченнай, Индия. Область научных интересов: встраиваемые системы, интернет вещей, системы реального времени, интеллектуальный системный дизайн, системы высокопроизводительных вычислений, многоядерные архитектуры и машинное обучение для управления батареями электромобилей. Член научных сообществ IEEE, IAEng, CSTA и HiPEAC, рецензент международных журналов и конференций.

Lordwin Cecil Prabhaker MICHEAL – PhD in Information and Communication Engineering (Anna University, 2018), Professor in the Department of Electronics and Communication Engineering at Vel Tech Rangarajan Dr. Sagunthala R&D Institute of Science and Technology, India. Research interests: embedded systems, IoT, real-time systems, smart system design, HPC systems, multicore architectures, and machine learning for EV battery management. Member of IEEE, IAEng, CSTA, and HiPEAC; reviewer for international journals and conferences.

