# УНИВЕРЗИТЕТ У БЕОГРАДУ МАШИНСКИ ФАКУЛТЕТ

Марко Н. Китановић

# ОПТИМИЗАЦИЈА ФУНКЦИОНАЛНИХ И УПРАВЉАЧКИХ ПАРАМЕТАРА ХИБРИДНОГ ПОГОНСКОГ СИСТЕМА ВОЗИЛА ЈАВНОГ ГРАДСКОГ ПРЕВОЗА

докторска дисертација

Београд, 2021.

# UNIVERSITY OF BELGRADE FACULTY OF MECHANICAL ENGINEERING

Marko N. Kitanović

# FUNCTIONAL AND CONTROL PARAMETERS OPTIMIZATION FOR A TRANSIT BUS HYBRID POWERTRAIN SYSTEM

Doctoral Dissertation

Belgrade, 2021.

Комисија за преглед и одбрану:

Датум одбране:

Ментор: Проф. др Слободан Ј. Поповић, ванредни професор, Универзитет у Београду -Машински факултет Чланови комисије: Проф. др Ненад Л. Миљић, ванредни професор, Универзитет у Београду -Машински факултет Проф. др Драган М. Кнежевић, ванредни професор, Универзитет у Београду -Машински факултет Доц. др Предраг Д. Мрђа, доцент, Универзитет у Београду – Машински факултет Проф. др Јован Ж. Дорић, ванредни професор, Универзитет у Новом Саду, Факултет техничких наука

**Наслов докторске дисертације:** "Оптимизација функционалних и управљачких параметара хибридног погонског система возила јавног градског превоза"

#### Сажетак

Погонски системи савремених возила предмет су истраживања великог броја научника широм света. Основни циљ истраживања огледа се у задовољавању све сложенијих и оштријих законских одредби у погледу токсичне издувне емисије и смањења потрошње горива, уз задржавање повољних перформанси возила. Хибридни погонски системи који, поред мотора са унутрашњим сагоревањем, обухватају и додатну погонску машину и алтернативни акумулатор енергије, нуде велике могућности у погледу уштеде горива. Од пресудне важности за остваривање потенцијалних уштеда јесу оптимизација функционалних и управљачких параметара система.

Предмет ове дисертације јесте експериментално и теоријско истраживање у области оптимизације хидрауличног хибридног погонског система намењеног погону возила јавног градског превоза путника. Важна одлика таквих система огледа се у употреби хидро-пнеуматских акумулатора које карактеришу ниске вредности специфичне енергије. Управо зато, јавља се потреба да се пажљивим избором параметара акумулатора омогући максимално прикупљање енергије кочења у фазама возног циклуса када ће и резултујуће уштеде у потрошњи бити највеће. Формирањем детаљног симулационог модела хидрауличног хибридног погонског система, извршено је одређивање утицаја масе еластомерне пене, притиска преднапрезања и радне запремине хидро-пнеуматског акумулатора на степен корисности погонског система у целини. Такође, испитана је могућност примене метода заснованих на неуронским мрежама у процесу извођења и примене оптималног управљачког алгоритма. На основу снимљених возних циклуса, формиран је оптималан алгоритам управљања употребом референтне методе динамичког програмирања који је потом употребљен као улазни скуп података за тренирање вештачких неуронских мрежа различитих конфигурација.

Применом функционалне оптимизације и предложене методе управљања, постигнуто је смањење потрошње горива од 23,9% у смеру кретања 1 и 25,5% у смеру кретања 2 и степен оптималности управљачког алгоритма од 83,7% и 79,8%, респективно.

**Кључне речи:** хибридни погонски системи, динамичко програмирање, оптимизација, управљање, енергетска ефикасност

#### Научна област: Машинство

Ужа научна област: Мотори са унутрашњим сагоревањем

УДК број: 629.34:629.3.064(043.3)

**Dissertation title:** Functional and control parameters optimization for a transit bus hybrid powertrain system

#### Abstract

Great scientific and engineering efforts are being invested in improving the fuel economy and emission performance standards of powertrain systems amid ever-increasing legislative pressure. Hybrid powertrain systems, comprising a conventional internal combustion engine and an additional prime mover and its corresponding energy storage system, offer great opportunities for fuel economy improvements. However, functional and control parameters optimization is of crucial importance in order to achieve the full extent of potential improvements.

The subject of this dissertation is experimental and theoretical investigation into the field of optimization of a hydraulic hybrid powertrain system intended for the propulsion of a transit bus. These hybrid propulsion solutions employ hydro-pneumatic accumulators for energy storage, which are characterized by low specific energy values. Because of this, it is of crucial importance to carefully choose the accumulator parameters in order to harness the maximum amount of regenerative braking energy during the deceleration phases that will yield the greatest fuel economy improvement. A comprehensive simulation model of a hydraulic hybrid powertrain system has been devised, which has allowed for the determination of the influence of elastomeric foam mass, preload pressure and accumulator capacity on the resulting powertrain system efficiency and the potential fuel savings. For maximizing the achievable fuel savings, a neural network-based control algorithm trained using the optimal control trajectories derived using Dynamic Programming has been investigated.

By applying the functional and optimal control optimizations presented in this dissertation, average fuel savings of 23.9% have been achieved in direction 1 of the transit bus driving cycle and 25.5% in direction 2. These figures represent 83.7% and 79.8% of the fuel economy improvements obtained using the unimplementable Dynamic Programming algorithm, respectively.

**Keywords:** hybrid powertrain systems, dynamic programming, optimization, control, energy efficiency

Scientific field: Mechanical engineering

Scientific subfield: Internal Combustion Engines

UDC number: 629.34:629.3.064(043.3)

### Списак слика

Слика 3.11: Нагиб пута и надморска висина за возни циклус у смеру 1
Слика 3.12: Зависности средњег позитивног убрзања, средње брзине возила у фазама
кретања, средње масе возила и укупног трајања циклуса на потрошену количину горива
за смер 126
Слика 3.13: Зависности средњег позитивног убрзања, средње брзине возила у фазама
кретања, средње масе возила и укупног трајања циклуса на потрошену количину горива
за смер 227
Слика 3.14: Идентификована мапа специфичне ефективне потрошње горива предметног
МСУС
Слика 3.15: Модел конвенционалног погонског система у програмском окружењу AMESim
Слика 3.16: Упоредни приказ снимљене и симулиране кумулативне потрошње горива
дуж читавог циклуса
Слика 3.17: Упоредни приказ снимљене и симулиране брзине кретања возила
Слика 3.18: Упоредни приказ снимљеног и симулираног броја обртаја мотора33
Слика 3.19: Упоредни приказ снимљене и симулиране потрошње горива дуж деонице
разматраног возног циклуса34
Слика 3.20: Мапа разматране хидрауличне машине [88]
Слика 3.21: Запремински степен корисности XM за притисак од 200 bar и број обртаја од
1500 min <sup>-1</sup>
Слика 3.22: Степен корисности XM за притисак од 200 bar и број обртаја од 1500 min <sup>-1</sup> 37
Слика 3.23: Мапа електричне машине
Слика 3.24: Поједностављен електрични модел ултракондензатора [93]40
Слика 4.1: Илустрација методе динамичког програмирања44
Слика 4.2: Смањење потрошње горива за ЕХПС са ограничењем од 300 А (број модула)46
Слика 4.3: Смањење потрошње горива за ЕХПС са ограничењем од 500 А (број модула)46
Слика 4.4: Смањење потрошње горива за ЕХПС без ограничења у јачини ел. струје (број
модула)47
модула)47 Слика 4.5: Смањење потрошње горива за ЕХПС са ограничењем од 300 А (степен
модула)47 Слика 4.5: Смањење потрошње горива за ЕХПС са ограничењем од 300 A (степен редукције)47
модула)47 Слика 4.5: Смањење потрошње горива за ЕХПС са ограничењем од 300 A (степен редукције)
модула)47 Слика 4.5: Смањење потрошње горива за ЕХПС са ограничењем од 300 A (степен редукције)
модула)

Слика 4.8: Апсолутна потрошња горива за ХХПС за случај 1
Слика 4.9: Релативно смањење потрошње горива за ХХПС за случај 1
Слика 4.10: Ток притиска и температуре гаса у хидро-пнеуматском акумулатору за
различите количине еластомерне пене (секција од 280 до 390 s разматраног циклуса,
случај 1)
Слика 4.11: Средње вредности притиска азота у хидро-пнеуматском акумулатору за
случај 1
Слика 4.12: Укупни степен корисности ХХПС за случај 151
Слика 4.13: Апсолутна потрошња горива за ХХПС за случај 252
Слика 4.14: Релативно смањење потрошње горива за ХХПС за случај 2
Слика 4.15: Средње вредности притиска азота у хидро-пнеуматском акумулатору за
случај 2
Слика 4.16: Укупни степен корисности ХХПС за случај 253
Слика 5.1: Процес машинског учења [103]55
Слика 5.2: Неурон са једним улазом [56]56
Слика 5.3: Неурон са R улаза [56]56
Слика 5.4: Једнослојна мрежа са S неурона и R улаза [56]56
Слика 5.5: Тгослојна мрежа са S неурона и R улаза [56]57
Слика 5.6: Нелинеарна, ауторегресивна мрежа са спољашњим улазом (NARX мрежа) [56]
Слика 5.7: Приказ једне NARX неуронске мреже са подразумеваним подешавањима59
Слика 5.8: Трајање спровођења оптимизационог прорачуна применом ДП за разматране
возне циклусе и конфигурацију ХПС61
Слика 5.9: Кутијасти дијаграм трајања процеса тренирања ВНМ у зависности од укупног
броја параметара за тренирање62
Слика 5.10: Подударање референтног и тока управљања на основу неуронске мреже, 4
неурона, задршка улаза 10, задршка стања 10 (варијанта 1)64
Слика 5.11: Подударање референтног и тока управљања на основу неуронске мреже, 4
неурона, задршка улаза 10, задршка стања 30 (варијанта 1)64
Слика 5.12: Подударање референтног и тока управљања на основу неуронске мреже, 4
неурона, задршка улаза 30, задршка стања 10 (варијанта 1)64
Слика 5.13: Подударање референтног и тока управљања на основу неуронске мреже, 4
неурона, задршка улаза 30, задршка стања 30 (варијанта 1)64

Слика 5.14: Подударање референтног и тока управљања на основу неуронске мреже, 8 Слика 5.15: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 10, задршка стања 30 (варијанта 1)......65 Слика 5.16: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 30, задршка стања 10 (варијанта 1)......65 Слика 5.17: Подударање референтног и тока управљања на основу неуронске мреже, 8 Слика 5.18: Подударање референтног и тока управљања на основу неуронске мреже, 12 Слика 5.19: Подударање референтног и тока управљања на основу неуронске мреже, 12 Слика 5.20: Подударање референтног и тока управљања на основу неуронске мреже, 12 Слика 5.21: Подударање референтног и тока управљања на основу неуронске мреже, 12 Слика 5.22: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 1......67 Слика 5.23: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 4 неурона (варијанта 1)......68 Слика 5.24: Расподела грешке праћења оптималног тока управљања за случај неуронске Слика 5.25: Расподела грешке праћења оптималног тока управљања за случај неуронске Слика 5.26: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 20 (варијанта 2).....70 Слика 5.27: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 60 (варијанта 2).....70 Слика 5.28: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 60, задршка стања 20 (варијанта 2).....71 Слика 5.29: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 60, задршка стања 60 (варијанта 2).....71 Слика 5.30: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 20, задршка стања 20 (варијанта 2).....71

Слика 5.31: Подударање референтног и тока управљања на основу неуронске мреже, 10
неурона, задршка улаза 20, задршка стања 60 (варијанта 2)71
Слика 5.32: Подударање референтног и тока управљања на основу неуронске мреже, 10
неурона, задршка улаза 60, задршка стања 20 (варијанта 2)72
Слика 5.33: Подударање референтног и тока управљања на основу неуронске мреже, 10
неурона, задршка улаза 60, задршка стања 60 (варијанта 2)72
Слика 5.34: Подударање референтног и тока управљања на основу неуронске мреже, 20
неурона, задршка улаза 20, задршка стања 20 (варијанта 2)72
Слика 5.35: Подударање референтног и тока управљања на основу неуронске мреже, 20
неурона, задршка улаза 20, задршка стања 60 (варијанта 2)72
Слика 5.36: Подударање референтног и тока управљања на основу неуронске мреже, 20
неурона, задршка улаза 60, задршка стања 20 (варијанта 2)73
Слика 5.37: Статистички параметри учинка разматраних конфигурација неуронских
мрежа према варијанти 274
Слика 5.38: Расподела грешке праћења оптималног тока управљања за случај неуронске
мреже са 4 неурона (варијанта 2)75
Слика 5.39: Расподела грешке праћења оптималног тока управљања за случај неуронске
мреже са 10 неурона (варијанта 2)75
Слика 5.40: Расподела грешке праћења оптималног тока управљања за случај неуронске
мреже са 20 неурона (варијанта 2)76
Слика 5.41: Аутокорелација оптималне расподеле оптерећења хибридног погонског
система77
Слика 5.42: Корелација брзине кретања возила и оптималне расподеле оптерећења77
Слика 5.43: Корелација укупног оптерећења хибридног погонског система и оптималне
расподеле оптерећења77
Слика 5.44: Корелација нормализованог оптерећења хидрауличне машине и оптималне
расподеле оптерећења
Слика 5.45: Корелација притиска азота у хидро-пнеуматском акумулатору и оптималне
расподеле оптерећења
Слика 5.46: Подударање референтног и тока управљања на основу неуронске мреже, 2
неурона, задршка улаза 10, задршка стања 30 (варијанта 3)
Слика 5.47: Подударање референтног и тока управљања на основу неуронске мреже, 6
неурона, задршка улаза 10, задршка стања 30 (варијанта 3)79

Слика 5.48: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)......79 Слика 5.49: Подударање референтног и тока управљања на основу неуронске мреже, 14 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)......79 Слика 5.50: Подударање референтног и тока управљања на основу неуронске мреже, 18 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)......80 Слика 5.51: Подударање референтног и тока управљања на основу неуронске мреже, 2 Слика 5.52: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)......80 Слика 5.53: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)......80 Слика 5.54: Подударање референтног и тока управљања на основу неуронске мреже, 14 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)......81 Слика 5.55: Подударање референтног и тока управљања на основу неуронске мреже, 18 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)......81 Слика 5.56: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 30, задршка стања 90 (варијанта 3)......81 Слика 5.57: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 30, задршка стања 90 (варијанта 3)......81 Слика 5.58: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 30, задршка стања 90 (варијанта 3)......82 Слика 5.59: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 3......83 Слика 5.60: Расподела грешке праћења оптималног тока управљања за случај неуронске Слика 5.61: Расподела грешке праћења оптималног тока управљања за случај неуронске Слика 5.62: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 10 неурона (варијанта 3)......84 Слика 5.63: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 14 неурона (варијанта 3)......85 Слика 5.64: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 18 неурона (варијанта 3)......85

Слика 5.65: Подударање референтног и тока управљања на основу неуронске мреже, 4 Слика 5.66: Подударање референтног и тока управљања на основу неуронске мреже, 8 Слика 5.67: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 60 (варијанта 4)......87 Слика 5.68: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 20, задршка стања 60 (варијанта 4)......87 Слика 5.69: Статистички параметри учинка разматраних конфигурација неуронских Слика 5.70: Расподела грешке праћења оптималног тока управљања за случај неуронске Слика 5.71: Расподела грешке праћења оптималног тока управљања за случај неуронске Слика 5.72: Подударање референтног и тока управљања на основу неуронске мреже, 2 Слика 5.73: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)......91 Слика 5.74: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)......91 Слика 5.75: Подударање референтног и тока управљања на основу неуронске мреже, 8 Слика 5.76: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)......91 Слика 5.77: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)......92 Слика 5.78: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)......92 Слика 5.79: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)......92 Слика 5.80: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)......92 Слика 5.81: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)......93 Слика 5.82: Подударање референтног и тока управљања на основу неуронске мреже, 2 Слика 5.83: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)......93 Слика 5.84: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)......93 Слика 5.85: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)......94 Слика 5.86: Подударање референтног и тока управљања на основу неуронске мреже, 10 Слика 5.87: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 5......95 Слика 5.88: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 2 неурона (варијанта 5)......96 Слика 5.89: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 4 неурона (варијанта 5).....96 Слика 5.90: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 6 неурона (варијанта 5)......97 Слика 5.91: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 8 неурона (варијанта 5)......97 Слика 5.92: Расподела грешке праћења оптималног тока управљања за случај неуронске Слика 6.1: Поређење релативног смањења потрошње горива ХПС у односу на КПС за три карактеристична циклуса у смеру кретања 1.....101 Слика 6.2: Поређење релативног смањења потрошње горива ХПС у односу на КПС за три карактеристична циклуса у смеру кретања 1 – осредњени излаз свих расположивих, Слика 6.3: Поређење релативног смањења потрошње горива ХПС у односу на конвенционални погонски систем за три карактеристична циклуса у смеру кретања 2...104 Слика 6.4: Поређење релативног смањења потрошње горива ХПС у односу на КПС за три карактеристична циклуса у смеру кретања 2 – осредњени излаз свих расположивих, успешно истренираних ВНМ......105 Слика А.1: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001 02 1, 270 001\_04\_1 u 270 001\_06\_1......122

Слика А.2: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001_08_1,
270 001_10_1 u 270 001_10_1
Слика А.3: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001_14_1,
270 001_16_1 u 290001_01_1
Слика А.4: Расподела убрзања и масе возила за возне циклусе са ознакама 290001_03_1,
<i>290001_05_1 u 290001_07_1</i>
Слика А.5: Расподела убрзања и масе возила за возне циклусе са ознакама 290001_09_1,
<i>290001_11_1 u 290001_13_1</i>
Слика А.6: Расподела убрзања и масе возила за возне циклусе са ознакама 310001_01_1,
<i>330001_01_1 u 330001_03_1127</i>
Слика А.7: Расподела убрзања и масе возила за возне циклусе са ознакама 330001_05_1,
<i>330001_07_1 u 350001_01_1</i>
Слика А.8: Расподела убрзања и масе возила за возне циклусе са ознакама 350001_03_1,
<i>350001_05_1 u 350001_07_1</i> 129
Слика А.9: Расподела убрзања и масе возила за возне циклусе са ознакама 350001_09_1,
<i>350001_11_1 u 350001_13_1</i> 130
Слика А.10: Расподела убрзања и масе возила за возне циклусе са ознакама 350001_15_1,
<i>360001_02_1 u 360001_04_1</i>
Слика А.11: Расподела убрзања и масе возила за возне циклусе са ознакама 360001_06_1,
<i>360001_08_1 u 360001_10_1</i>
Слика А.12: Расподела убрзања и масе возила за возне циклусе са ознакама 360001_12_1,
<i>370 001_01_1 u 370 001_03_1</i>
Слика А.13: Расподела убрзања и масе возила за возне циклусе са ознакама 270001_01_2,
270 001_03_2 u 270 001_05_2
Слика А.14: Расподела убрзања и масе возила за возне циклусе са ознакама 270001_07_2,
270 001_09_2 u 270 001_11_2
Слика А.15: Расподела убрзања и масе возила за возне циклусе са ознакама 270001_13_2,
270 001_15_2 u 290001_02_2
Слика А.16: Расподела убрзања и масе возила за возне циклусе са ознакама 290001_04_2,
<i>290001_06_2 u 290001_08_2</i>
Слика А.17: Расподела убрзања и масе возила за возне циклусе са ознакама 290001_10_2,
<i>290001_12_2 u 290001_14_2</i> 138
Слика А.18: Расподела убрзања и масе возила за возне циклусе са ознакама 330001_02_2,
<i>330001_04_2 u 330001_06_2</i> 139

Слика А.19: Расподела убрзања и масе возила за возне циклусе са ознакама 330001_08_2,
<i>350001_02_2 u 350001_04_2</i> 140
Слика А.20: Расподела убрзања и масе возила за возне циклусе са ознакама 350001_06_2,
<i>350001_08_2 u 350001_10_2</i> 141
Слика А.21: Расподела убрзања и масе возила за возне циклусе са ознакама 350001_12_2,
350001_14_2 u 360001_01_2142
Слика А.22: Расподела убрзања и масе возила за возне циклусе са ознакама 360001_03_2,
<i>360001_05_2 u 360001_07_2</i>
Слика А.23: Расподела убрзања и масе возила за возне циклусе са ознакама 360001_09_2,
<i>360001_11_2 u 360001_13_2</i> 144
Слика А.24: Расподела убрзања и масе возила за возни циклус <i>са ознаком 370001_02_2</i> 145

## Списак табела

Табела 3.1: Пример снимљене поруке са CAN мреже23
Табела 3.2: Границе категорија према критеријуму укупног трајања возног циклуса27
Табела 3.3: Границе категорија према критеријуму средње брзине приликом кретања
возила
Табела 3.4: Резултати оптимизације параметара коефицијента отпора котрљања возила32
Табела 3.5: Електричне карактеристике разматраних конфигурација ултракондензатора40
Табела 4.1: Преглед функционалних променљивих за ЕХПС46
Табела 4.2: функционални параметри ХХПС49
Табела 5.1: Преглед дефиниција преносних функција код неуронских мрежа [56]57
Табела 5.2: Функционални параметри ХХПС коришћени за формирање скупа података за
тренирање неуронске мреже60
Табела 5.3: Приказ и опис коришћених варијанти подешавања вештачких неуронских
мрежа
Табела 5.4: Приказ учинка процеса тренирања неуронских мрежа према варијанти 163
Табела 5.5: Приказ учинка процеса тренирања неуронских мрежа према варијанти 270
Табела 5.6: Приказ учинка процеса тренирања неуронских мрежа према варијанти 378
Табела 5.7: Приказ учинка процеса тренирања неуронских мрежа према варијанти 486
Табела 5.8: Приказ учинка процеса тренирања неуронских мрежа према варијанти 590
Табела 6.1: Карактеристике возних циклуса изабраних за утврђивање учинка ВНМ99
Табела 6.2: Карактеристике ВНМ изабраних за спровођење валидације управљачке методе
Табела А.1: Снимљени возни циклуси у смеру 1 - апсолутне вредности
Табела А.2: Снимљени возни циклуси у смеру 2 - апсолутне вредности
Табела А.3: Снимљени возни циклуси у смеру 1 - средња квадратна одступања118
Табела А.4: Снимљени возни циклуси у смеру 2 - средња квадратна одступања119
Табела А.5: Основни параметри снимљених циклуса са редним бројем категорија 1 и 2 за
смер 1120
Табела А.6: основни параметри снимљених циклуса са редним бројем категорија 1 и 2 за
смер 2121

## 1 Уводна разматрања

#### 1.1 Енергетски аспекти сектора транспорта људи и робе

Енергија је основни ресурс човечанства. Издашне количине енергије по приступачним ценама основни су услов за одржање и развој цивилизације. За сада су у стању да то омогуће само необновљива, фосилна горива попут нафте, угља, природног гаса. Њихове повољне карактеристике, попут високе специфичне енергије, доступности, постојаности, приступачности, учиниле су да горива на бази угљеника сасвим потисну обновљиве изворе енергије и омогуће несагледиви економски и раст броја становника на планети.



Слика 1.1: Расподела коришћења примарне енергије у свету према врсти горива [1]

Процењује се да око 85% искоришћене енергије у свету потиче из енергената на бази угљеника [2]. На слици 1.2 приказана је расподела коришћења енергије у свету према секторима. Други по величини је сектор транспорта, са око 25% удела у укупној потрошњи енергије у свету. Прогнозе показују да ће у земљама ОЕБС-а доћи стагнације или чак и благог пада у потрошњи енергије у поменутом сектору у наредних 30 година. Наиме, побољшања у степену корисности биће нешто већа од пројектованих повећања потреба за транспортом. У земљама које нису чланице ОЕБС-а прогнозира се повећање енергетских потреба у сектору транспорта за нешто мање од 80% у периоду од 2018 до 2050. године, када ће енергетске потребе свих земаља ван ОЕБС-а чинити 65% од укупне потражње (слика 1.3).



На сликама 1.4 и 1.5 приказане су историјске и прогнозиране потрошње енергије за потребе транспорта путника и робе, респективно. Потребе за енергијом достићи ће свој највећи раст у земљама ван ОЕБС-а, и то у свим категоријама превоза путника, од путничких возила, преко аеро-транспорта до шинског транспорта и аутобуса. Такође, прогнозира се велики раст у потрошњи енергије за потребе транспорта робе у земљама које нису чланице ОЕБС-а услед очекиваног индустријског раста. Највећи део тог пораста очекује се у области транспорта робе камионима највећих носивости.

Сви ови подаци упућују на велику потребу за повећањем ефикасности погонских система свих врста возила ради уштеде енергије и смањења негативних утицаја на животну средину.

Passenger transportation energy consumption quadrillion British thermal units

Freight transportation energy consumption



Слика 1.4: Расподела енергије за путнички транспорт према врсти возила [3]



#### 1.2 Предмет и циљ истраживања

Погонски системи савремених возила предмет су великог броја истраживања широм света. Основни недостатак конвенционалних погонских система (у даљем тексту КПС) који се састоје искључиво од мотора са унутрашњим сагоревањем (у даљем тексту ХПС) јесте мали ефективни степен корисности у реалним експлоатационим условима. Иако се на полу економичности савремених МСУС често постижу вредности степена корисности изнад 40% [4], у реалним условима градске вожње са ниским вредностима оптерећења мотора и честим застојима, просечни постигнути степен корисности износи око 20% [5]. Око 80% топлотне енергије ослобођене током сагоревања бива неискоришћено у таквим експлоатационим условима. Један од најперспективнијих начина за повећање средње постигнуте ефикасности погонских система налази се у побољшању логистике саобраћаја и увођењу аутономних возила [6], [7]. Хибридизација погона [8] је други начин за побољшање степена корисности. Хибридни погонски систем је онај систем који обухвата најмање два засебна извора енергије, од којих је најмање један реверзибилан. Тиме се

омогућује примена регенеративног кочења и складиштење кинетичке енергије возила и њено касније коришћење у фазама убрзања.

Поред повећања степена корисности, основни циљ поменутих истраживања огледа се и у задовољавању све сложенијих и оштријих законских одредаба у погледу токсичне издувне емисије уз задржавање повољних перформанси возила [9]–[12].

Комунална возила, као што су возила градске чистоће и возила јавног превоза, су високоспецијализована возила која основни задатак, као што су одношење смећа, односно превоз путника по унапред дефинисаним трасама и терминима, обављају ефикасније од возила за опште намене. Централизација у овом случају има и повољне ефекте у погледу унапређења економичности јер повећање масе возила погодује примени одређених решења хибридних погонских система које карактерише висока специфична снага (код, на пример, хидрауличних хибридних система) [13].

Један од највећих изазова који треба превазићи пре већег пробоја хибридних погонских система јесте оптимизација функционалних и управљачких параметара система. Функционални параметри хибридног погонског система подразумевају:

- енергетске капацитете акумулатора енергије,
- претварача снаге (мотори/генератори код електричних хибридних система, мотори/пумпе код хидрауличних хибридних погонских система),
- диспозицију алтернативног погонског система
- и преносне односе између конвенционалног и алтернативног погонског агрегата.

Оптимални функционални параметри зависе од:

- масе и носивости возила,
- возног циклуса (профила брзине и убрзања, конфигурације терена, итд.)

и као такви представљају компромис за одређени скуп утицајних фактора који су најчешће присутни код објекта оптимизације.

Са друге стране, постојање додатне погонске машине и алтернативног акумулатора енергије условљава потребу оптимирања управљачких параметара хибридног система. Наиме, за сваки тренутак и захтевано оптерећење погонског система, потребно је установити оптималну расподелу оптерећења између МСУС и додатне погонске машине ради смањења укупне потрошње горива током разматраног возног циклуса и најефикаснијег искоришћења енергије добијене у фазама регенеративног кочења возила.

Поменути проблеми оптимизације могу се релативно лако решавати уз помоћ потврђених и робусних математичких метода, попут динамичког програмирања (ДП у даљем тексту) [14]–[20]. Један од недостатака динамичког програмирања јесте релативно дуго време решавања алгоритма, које експоненцијално расте са бројем стања система [21]. Са друге стране, предност ове методе јесте у томе што се решавањем рекурзије добија глобално оптимално решење оптимизације, што је основни разлог зашто динамичко програмирање и даље представља једно од најбољих решења за оптимизацију управљања код хибридних погонских система. Поред свега побројаног, главни недостатак рекурзивних метода огледа се у томе што се процес оптимизације, услед потребе да се

целокупан проблем унапред дефинише, не може одвијати у реалном времену. Другим речима, на овај начин добијени резултат оптимизације не може се превести у алгоритам управљања и применити на разматраном објекту. Ова чињеница отвара простор за велики број истраживања са циљем примене резултата "offline" оптимизације и извођења алгоритма управљања који ће применом на разматраном објекту резултирати перформансама које теже оптималним.

Предмет ове дисертације јесте истраживање у области оптимизације хибридног погонског система за тешка возила применом метода ДП и математичких модела заснованих на вештачким неуронским мрежама, на основу експериментално добијених података са возила јавног градског превоза.

## 2 Хибридни погонски системи

## 2.1 Дефиниција, преглед врста система

Хибридни погонски системи (у даљем тексту ХПС) су они системи који, поред МСУС, обухватају и још један претварач са припадајућим акумулатором енергије који је реверзибилан и који учествује у погону возила [22]. Овако прецизна дефиниција потребна је како би се из скупа хибридних возила искључили конвенционални аутомобили који поседују батерију и електро-покретач и алтернатор и погонски системи који поседују најмање два енергетска извора а који немају могућност регенеративног кочења.

У зависности од врсте секундарног, реверзибилног претварача енергије, овакви системи могу бити електрични, механички, хидраулични или пнеуматски.

У општем случају, хибридни погонски системи доносе велики број предности, међу које се могу набројати и:

- Могућност регенеративног кочења услед коришћења реверзибилног енергетског ланца, кинетичка енергија возила може се претворити у облик погодан за акумулацију и касније искористити на ефикасан начин.
- Већи степен корисности алтернативних погонских машина електрични и хидраулични мотори су знатно ефикаснији од МСУС.
- Бољи облик криве момента у односу на моторе СУС електричне машине карактеришу високе вредности расположивог обртног момента на ниским вредностима броја обртаја, што је погодније са аспекта потребе возила.
- Боља возивост електричне и хидрауличне машине имају бољи одзив од МСУС, омогућујући динамичне промене оптерећења, према потребама возила.
- Смањење емисије токсичних издувних гасова и честица кроз могућност елиминације прелазних радних режима МСУС и искључења мотора на празном ходу, смањује се емисија токсичних издувних гасова и честица. Такође, употребом регенеративног кочења, постиже се смањење емисије честица проистеклих употребом фрикционих кочница возила.
- У зависности од конфигурације ХПС, отвара се могућност рада МСУС на полу економичности, односно на линији максималних степена корисности.
- Могућност рада помоћних уређаја возила на алтернативни погон електрификација истих омогућила би њихов оптималан рад и минималну потрошњу енергије уз потенцијално искључење МСУС.

У недостатке хибридизације погона убрајају се:

• Повећање цене возила – ради економске одрживости, потребно је осигурати се да ће повећана улагања у хибридизацију бити испраћена довољним уштедама у експлоатационим условима током радног века система.

- Повећање комплексности погона које, начелно гледано, може довести до смањења поузданости целокупног система. У одређеним случајевима, на пример код употребе паралелних хибридних погонских система (у даљем тексту ПХПС), могуће је повећање поузданости услед могућности независног рада погонских машина.
- Повећање масе система додатне погонске машине (хидраулични мотори/пумпе и електрични мотори/генератори) и акумулатори енергије (хидро-пнеуматски акумулатори и електрохемијске батерије) повећавају масу целокупног система. Потребно је проценити да ли ће утицај додатне масе поништити побољшања у степену корисности погонског система (у даљем тексту ПС).
- Сложени алгоритми управљања услед повећања степена слободе које алтернативни погонски систем доноси, систем управљања знатно је сложенији. Додатни проблем лежи у значајној осетљивости оптималних управљачких параметара и постигнуте уштеде у потрошњи горива од возног циклуса.

Код путничких возила, најчешћи су електрични хибридни погонски системи (у даљем тексту ЕХПС), код којих је мотор са унутрашњим сагоревањем примарни покретач, а електрични мотор, генератор, акумулатор енергије (најчешће електрохемијска батерија) представљају други, секундарни погонски ланац који је реверзибилан. Први модерни, серијски произведени хибридни погонски системи за путничка возила појавили су се крајем 90. година прошлог века, са појавом модела Тоуоta Prius и Honda Insight [23], [24]. Код оба модела електрична машина се користи за апсорпцију кинетичке енергије возила у електрични акумулатор током фаза кочења возила. Касније, током фаза убрзања или на ниским оптерећењима, где мотор СУС постиже ниске вредности степена корисности, акумулирана енергија кочења ослобађа се и на тај начин се постижу уштеде у гориву.

Према врсти алтернативног ланца коју ХПС користи, акумулатори енергије могу бити електричног типа, хидро-пнеуматског или механичког. Код ЕХПС, уобичајено је да се користе електрохемијске батерије и ултракондензатори. Карактеристике батерија увелико зависе од врсте материјала од којих су направљене електроде и врсте електролита. Најчешће коришћене батерије у ауто-индустрији јесу оловне, код којих су електроде на бази олова, а као електролит користи се сумпорна киселина. Оне се користе за складиштење довољне количине енергије за укључење мотора у неповољним условима и за напајање електричних уређаја у возилу. Поред предности које такве батерије нуде, попут поузданости и ниске цене, ниске вредности специфичне енергије и кратак животни век чине их неповољним за погонске системе данашњице. Код ЕХПС се најчешће користе батерије са електродама на бази литијума и различите комбинације електролита које нуде различите компромисе у погледу животног века, специфичне енергије и снаге ћелија, стабилности и сигурности, цене и утицаја на животну средину. Оно што је заједничко за све врсте електрохемијских акумулатора јесу релативно ниске вредности специфичне снаге које их чине неподесним за примену код тешких возила.

На слици 2.1 приказана су поља очекиваних вредности снаге и учестаности кочења за поједине класе возила. За путничка возила која имају релативно мале масе у односу на друга, високо-специјализована возила попут аутобуса, камиона, возила комуналних служби, карактеристичне су мале снаге и фреквенције кочења. То их чини прикладним за решења хибридизације која користе електричне машине и акумулаторе енергије малих

снага (електрохемијске батерије). Остале врсте возила обухватају много већи опсег фреквенција кочења, од камиона са најмање честим фазама успорења до комуналних возила за одношење смећа са најучесталијим заустављањима. Заједничко за сва остала возила јесте и то да су вредности снаге кочења значајно веће него код путничких возила. Ако је циљ хибридизације што веће искоришћење кинетичке енергије возила током процеса кочења, тешко је очекивати да електрохемијски акумулатори представљају идеално решење.



Слика 2.1: Карактеристике снаге и фреквенције кочења за различите врсте возила [25]



Слика 2.2: Поређење батерија према карактеристици специфичне снаге и енергије [26]

На слици 2.2 приказане су области специфичне енергије и снаге за акумулаторе енергије који се користе код ЕХПС. У погледу максималних снага, ултракондензатори показују најбоље карактеристике. Са друге стране, литијум-јонске батерије карактеришу врло високе вредности специфичне енергије, које су за око 20 пута веће у односу на ултракондензаторе. Такође, оне се могу користити и код система са високим захтевима у погледу снаге, али у тим случајевима су вредности специфичних енергија ниже.

На слици 2.3 приказани су опсези специфичних енергија и снага за различите врсте акумулатора енергије. У областима високих специфичних снага налазе се хидраулични, механички (замајац) и електрични (ултракондензатори) акумулатори. Карактеристично за ултракондензаторе и хидрауличне акумулаторе јесу и мале вредности специфичне енергије, те нису прилагођени за дуготрајно прикупљање енергије. Треба напоменути да је дијаграм приказан у логаритамској скали и да је, за исту вредност специфичне снаге, специфична енергија бензина за око 10 пута већа од литијум-јонске батерије једног ЕХПС. То се преводи у 10 пута већи домет возила по јединици масе акумулатора.



Слика 2.3: Поређење опсега специфичне енергије и снаге различитих врста акумулатора енергије (Рагонијев дијаграм) [26]

У овој дисертацији биће разматрани искључиво системи који користе хидро-пнеуматске и ултракондензаторске акумулаторе.

## 2.2 Подела ХПС према архитектури

У зависности од потреба и намене возила за које се ХПС пројектује, диспозицијом основних елемената могу се остварити различите архитектуре система. Наиме, према

томе како је конфигурисан хибридни погонски систем, он може бити серијски, паралелни или комбиновани.

Код ПХПС, и примарна погонска машина – МСУС, као и секундарна погонска машина имају механичку везу са погонским точковима возила. Једна таква конфигурација приказана је на слици 2.4. Начелно гледано, додатна погонска машина може се поставити било где на путу од замајца мотора до погонских точкова. Оптимална локација зависи од врсте алтернативне машине, намене возила, типичног возног циклуса, итд. Код ПХПС није потребно користити засебни генератор, већ ту функцију могу преузети електрични, односно хидраулични мотор. Важна одлика оваквих система огледа се у могућности симултаног рада оба претварача енергије у фазама убрзања возила. Тиме се омогућује смањење радне запремине МСУС (тзв. *downsizing* мотора) које доноси укупно побољшање степена корисности на два начина: смањењем укупне масе возила и премештањем радних режима МСУС у подручја са вишим оптерећењима, где је специфична ефективна потрошња горива нижа.



Слика 2.4: Диспозиција елемената погонског система код паралелног ХХПС [27]

У погледу функционалности коју додатни претварач енергије и припадајући акумулатор пружају, ХПС се могу поделити на микро, делимичне (енг. *mild*) и потпуне (енг. *full*) системе [28].

Микро хибриди обухватају крени/стани системе (енг. *start/stop*) код којих се МСУС искључује када је захтевани обртни момент за погон возила једнак нули и када су испуњени сви остали услови (задовољене потребе за електричном енергијом помоћних уређаја и потрошача на возилу, довољно висока вредност стања напуњености батерије, итд.). Такви системи у највећем броју случајева састоје се из ЕМ која замењује стандардни алтернатор и електро-покретач, претварача напона и електрохемијске батерије. Попуштањем кочнице или притиском на папучицу која управља спојницом мотора, ЕМ покреће МСУС. Овим системом могућа је и оптимизација процеса пуњења акумулатора, који се може активирати у фазама успорења возила или при раду МСУС на повишеним оптерећењима.

Делимични хибридни системи обухватају оне системе код којих алтернативни претварач енергије учествује у погону возила. Код тих ХПС могуће је извршити оптимизацију расподеле оптерећења између примарног и секундарног претварача енергије. Потпуни хибридни погонски системи су они код којих алтернативни претварач енергије може самостално пружати потребну погонску снагу потрошачу.

Код паралелне конфигурације могућ је и рад МСУС на вишим оптерећењима од укупно потребних за погон возила, где се вишак снаге апсорбује на секундарној машини и тиме допуњује енергетски акумулатор. За разлику од серијске конфигурације ХПС, број обртаја коленастог вратила (у даљем тексту КВ) мотора није независна променљива у односу на брзину кретања возила.



Слика 2.5: Паралелни ХХПС од ЕРА [29]

Америчка агенција за заштиту животне средине (енг. United States Environmental Protection Agency) извршила је у периоду од 1993. до 2012. године бројна истраживања на тему примене хидрауличних хибридних погонских система (у даљем тексту ХХПС) на тешким возилима разних категорија. Развијене су ХХПС технологије за примену на возилима за одношење смећа, доставним возилима, аутобусима и грађевинским машинама попут багера, дизалица, итд.

Развијен је паралелни хидраулични ХПС (у даљем тексту ПХХПС, слика 2.5) за возило класе 3 (масе до приближно 6400 kg). Постигнуто је смањење потрошње горива до 23% у односу на конвенционални погонски систем [29]. Због ограничених уштеда у потрошњи горива условљених немогућностима независног управљања радним режимима МСУС, одлучено је да ће се даља истраживања концентрисати на серијске ХХПС (у даљем тексту СХХПС).

Електрична машина (у даљем тексту ЕМ) код паралелних ЕХПС (у даљем тексту ПЕХПС) може бити постављена на неколико начина, као што је приказано на сликама 2.6 и 2.7. Паралелни системи не захтевају засебан електрични генератор јер ЕМ може радити у оба захтевана режима.

Код система где је ЕМ постављена између спојнице и трансмисије, ЕМ може бити релативно малих димензија због постојања редукције у преноснику. Такође, у односу на ЕХПС који су састављени искључиво од електро-покретача и алтернатора и повезани директно на коленасто вратило (микро-хибридни погонски систем [30]), мотор СУС се може искључити и погон возила може бити преузет искључиво од електромотора.

Системи са ЕМ постављеном иза мењача морају бити већих димензија и бити усклађени са брзинским индексом точка. Тиме се повећава и маса целокупног система али се омогућују већи степени корисности регенерације енергије.



Слика 2.6: Паралелни ЕХПС са ЕМ постављеном иза преносника [26]



Слика 2.7: Паралелни ЕХПС са ЕМ постављеном испред преносника [26]

Код серијског хибридног погонског система (у даљем тексту СХПС), механичку везу са погонским точковима остварује само секундарна машина (у случају приказаном на слици само хидрауличне машине), а МСУС је директно везан за генератор електричне, односно хидрауличне енергије. На тај начин извршено је механичко раздвајање МСУС и погонских точкова, са могућношћу одабира оптималног радног режима за захтевану вредност снаге. Пошто погонски систем мора бити у стању да одржи захтеване перформансе на неодређено време, СХПС (слика 2.8) морају бити димензионисани тако да обе машине буду прописане номиналне снаге. Због тога, овакви системи начелно имају веће масе од еквивалентних система са паралелном архитектуром. Због додатне фазе претварања енергије горива, од кључне важности је да компоненте СХПС имају високе степене корисности. Наиме, у условима саобраћаја са малим променама путне брзине и без наглашених фаза успорења, постоји опасност од повећања потрошње горива у односу на еквивалентни КПС.



Лика 2.8: Диспозиција елемената погонског система код серијског ХХПС [27]

У фазама успорења возила, хидрауличне машине које се налазе на погонској страни система апсорбују кинетичку енергију возила и потискују уље из нископритисних резервоара у хидро-пнеуматски акумулатор енергије који је најчешће састављен од мехура који је испуњен азотом. У фазама убрзања возила, уље из хидро-пнеуматског акумулатора под великим притиском спроводи се до хидрауличних машина које сада преузимају улогу мотора и на тај начин ослобађају механичку енергију погонским точковима. Хидраулична машина која се налази на страни МСУС служи за претварање механичке у хидрауличну енергију која се складишти у хидро-пнеуматском акумулатору. Поменута машина може преузети и улогу хидрауличног мотора и покренути МСУС када је то потребно.



Слика 2.9: Поређење поља радних режима мотора СУС код конвенционалног и СХПС [31]

На слици 2.9 приказан је универзални дијаграм специфичне ефективне потрошње горива са назначеним радним пољима код конвенционалног погонског система и СХПС за разматрани возни циклус. Пошто је код СХПС могуће слободно изабрати радни режим мотора за захтевану погонску снагу, велике уштеде у потрошњи горива могу се постићи премештањем радних режима мотора СУС у подручја са већим оптерећењем, тј. у области рада са вишим степеном корисности (повољнији однос ефективне снаге и снаге механичких губитака). Наиме, за сваку вредност снаге постоји комбинација броја обртаја и оптерећења мотора са највећим степеном корисности. У експлоатацији, управљачки систем треба да одређеном динамиком пролази кроз на тај начин дефинисане оптималне радне тачке мотора, водећи рачуна о емисији токсичних издувних материја проузрокованих транзијентним радним режимима [11], [12]. Иако је могуће искључиво користити пол економичности мотора током рада СХХПС, показано је да специфична потрошња горива по јединици развијене снаге, тј. степен корисности система зависи увелико и од прелазних радних режима проузрокованих сукцесивним укључивањем и искључивањем мотора СУС и од степена корисности хидрауличне пумпе [12].

Од 2005. до 2012. америчка ЕРА развијала је различите конфигурације СХХПС. На крају је развијен интегрисани погонски систем (слике 2.10, 2.11) састављен од моторске и погонске хидрауличне машине реверзибилног типа (способне да појединачно преузму улоге мотора и пумпе) и преносног механизма са укупно 6 преносних односа између погонске хидрауличне машине и точкова. Тај погонски систем био је примењен на аутобусу класе 6.

Резултати у реалним експлоатационим условима показали су значајне уштеде у потрошњи горива од преко 40% у типичним градским условима и до око 60% у условима великих застоја у односу на конвенционални погонски систем. Интересантно је

напоменути и да је и у условима вожње на аутопуту овај погонски систем показао уштеде од 23%, што је изванредан резултат за СХПС.



Слика 2.10: Серијски ХХПС за погон аутобуса (ЕРА) [29]



система СХХПС развијеног од стране ЕРА [29]

## 2.3 Проблематика оптимизације и управљања радом

#### система

Хибридни погонски системи нуде велики спектар могућности у спровођењу и постизању циљева у погледу смањења потрошње горива и токсичне издувне емисије. Пуни потенцијал унапређења може се достићи искључиво оптимизацијом функционалних и управљачких параметара целокупног погонског система. Утицајни параметри на оптималну конструкцију и управљање јесу:

- врста возила,
- типични возни циклуси,
- ограничења у смештајном простору,
- маса возила,
- економска питања, итд.

С обзиром на то да су предмет ове дисертације тешка возила, тј. возила намењена градском превозу путника, посебна пажња биће посвећена ХХПС као посебно прикладним решењима захваљујући врло високим вредностима специфичне снаге. Један од недостатака тих система огледа се у релативно малој количини енергије која се може апсорбовати у одговарајућим енергетским акумулаторима, што представља додатни изазов у погледу оптимизације управљања радом таквих система.

Хибридни погонски системи поседују најмање два погонска ланца, за одређени захтевани обртни момент на погонским точковима постоји неограничени број комбинација стања радних режима МСУС и секундарног погонског ланца. У том смислу, задатак оптимизације управљачких параметара огледа се у одабиру оних стања система који ће да минимизују, односно максимизују, одређени критеријум учинка система. Критеријум учинка може, на пример, бити:

- укупна количина потрошеног горива,
- трајање возног циклуса,
- укупна количина емитованих загађујућих материја
- или комбинација више различитих показатеља.

Знатан број радова (међу којима [12], [18], [32]–[34]) објављен је на тему примене и оптимизације хибридних погонских система код тешких возила, који потврђују велику сложеност и деликатност у процесу одабира функционалних параметара система као и оптимизације управљања.

У раду [18] формиран је симулациони модел ПХХПС намењеног погону средње тешког доставног возила. Употребом ДП, извршена је оптимизација управљачких параметара – расподеле оптерећења између МСУС и хидрауличне машине, као и степена преноса. Употребљен је један хидро-пнеуматски акумулатор радне и укупне запремине од 50 и 100 dm<sup>3</sup>, респективно. Извршена је оптимизација система за само један притисак преднапрезања акумулатора од 125 bar. Коришћен је аналитички модел акумулатора где је стање гаса описано Првим законом термодинамике и једначином стања реалног гаса. Анализом оптималне путање стања система, изведен је једноставан модел управљања који користи унапред дефинисана правила на основу тренутног стања напуњености хидро-пнеуматског акумулатора и траженог оптерећења погонског система.

У раду [34] анализиран је погонски систем за возило намењено одношењу комуналног отпада. Моделиран је паралелни хидраулични хибридни погонски систем који обухвата дизел-мотор и хидрауличну машину која је постављена иза мењачког преносника. Користи се аналитички модел хидро-пнеуматског акумулатора (укупне запремине од 32 dm<sup>3</sup>) који је базиран на примени Првог закона термодинамике и Бенедикт-Веб-Рубинове (*Benedict-Webb-Rubin*) једначине стања реалног гаса. Ни у овом раду није анализиран утицај функционалних параметара (притиска преднапрезања, масе еластомерне пене и запремине акумулатора) на степен корисности самог акумулатора или на систем у целини. За оптимизацију и формирање управљачког сигнала употребљена је метода стохастичког динамичког програмирања, где је укупно оптерећење погонског система моделиран као Марковљев процес. Оптимална решења су дискретизована и формирано је укупно 16 мапа које у функцији стања напуњености акумулатора, траженог оптерећења погонског система и брзине кретања возила дају оптималну расподелу оптерећења хибридног система.

У раду [12] разматран је проблем оптимизације управљања хидрауличног хибридног погонског система намењеног вишенаменском теренском возилу. Формиран је симулациони модел возила и хидрауличног система који је серијски спрегнут са мотором са унутрашњим сагоревањем. Коришћен је аналитички модел хидропнеуматског акумулатора уз помоћ кога је извршена анализа утицаја термалне временске константе и масе еластомерне пене на степен корисности самог акумулатора. Међутим, није извршена анализа ових параметара у погледу утицаја на степен корисности целокупног погонског система, нити је разматран утицај масе гаса, тј. притиска преднапрезања на учинак акумулатора и система. Коришћен је акумулатор укупне запремине од 86 dm<sup>3</sup> и узето је да је притисак преднапрезања 125 bar.

Посебан проблем код ХХПС огледа се у што ефикаснијој употреби малих енергетских капацитета хидро-пнеуматских акумулатора. Мали број истраживања је посвећен проблематици оптимизације функционалних параметара тих акумулатора и утврђивања утицаја њихових појединих радних параметара на укупни степен корисности погонског система.

У највећем броју случајева, за одређивање оптималног (референтног) управљања користи се метода ДП. Сама метода, иако настала током педесетих година прошлог века [35], и данас се користи за успостављање оптималног алгоритма управљања на основу постављеног проблема, граничних услова и критеријума оптимизације. Нажалост, највећи недостатак ове методе јесте немогућност примене на објектима чије функционисање је потребно оптимирати у реалном времену јер је један од потребних услова познавање стања система у читавом временском домену оптимизације. Због немогућности тачног предвиђања будућих стања погонског система током кретања возила, немогуће је постићи апсолутну оптимизацију у реалном времену већ искључиво тежити глобалном оптимуму.

У раду [36] коришћена је метода ДП за секвенцијалну оптимизацију конструкције и закона управљања ХХПС за тактичко борбено возило са погоном на свих 6 точкова. Најпре је развијен а потом и проверен модел конвенционалног погонског система предметног возила, након чега је дограђен модел ХПС разматране архитектуре, са иницијалном конструкцијом и капацитетом алтернативног погонског система. Надаље је примењен репрезентативни возни циклус и задат почетни начин управљања заснован на унапред дефинисаним правилима. Потом је извршена оптимизација функционалних параметара ХПС на основу секвенцијалног квадратног алгоритма са граничним условима који треба да осигурају довољно добре перформансе возила. Након тога извршена је оптимизација управљачких параметара применом ДП ради одређивања оптималне расподеле оптерећења и алгоритма промене степена преноса мењачког механизма. На основу тих резултата, извршена је анализа на основу које је ажуриран алгоритам управљања. Друга фаза оптимизације, чији је задатак да примени утицај оптималног управљања на конструкцију ХПС, извршена је, чиме је обезбеђена комбинована оптимизација функционалних и управљачких параметара система. На крају, резултати уштеде у потрошњи горива упоређени су са унапред дефинисаним циљевима и уколико они нису постигнути, читава процедура понавља се за другачију конфигурацију ХПС.

#### 2.3.1 Примењиве методе за тренутну оптимизацију управљања ХПС

Од метода за оптимизацију погонског система које је могуће применити на возилима и за чији рад је потребно познавање стања система само до тренутка одлучивања (такозвана оптимизација у реалном времену – "real-time" или "online" оптимизација), користе се методе засноване на унапред дефинисаним правилима (RBC – Rule-Based Control). Овакве методе заснивају се на тренутном одређивању расподеле оптерећења између МСУС и алтернативног погонског система (у даљем тексту АПС) на бази уграђене логике и граничних услова система. Оне подразумевају термостатске контроле, управљања која користе мапе добијене извођењем правила из оптималних алгоритама управљања, итд. Термостатска контрола најчешће подразумева поделу радног поља мотора у одређене регије које дефинишу понашање погонског система. На пример, у [37] је приказан модел управљања за ПХХПС. Најпре је одређена крива оптималне потрошње МСУС добијена спајањем радних режима са најнижим вредностима специфичне ефективне потрошње горива за одређени опсег ефективних снага мотора. Уколико се тренутни радни режим мотора налази изнад задате криве оптималне потрошње, проверава се да ли је притисак у акумулатору изнад минимално задатог и у том случају се активирају обе погонске машине. Уколико се тренутни радни режим налази испод криве оптималне потрошње за неку вредност обртног момента која је већа од  $\Delta T$ , могућа су два начина рада: истовремени погон и активно пуњење акумулатора МСУС уколико притисак у акумулатору није већи од граничне вредности активног пуњења р, и погон хидрауличним уређајем уколико је притисак већи од граничног. На крају је извршена оптимизација параметара овог закона управљања (параметара  $\Delta T$  и  $p_c$ ) путем генетичког алгоритма. У бројним радовима приказани су закони управљања овог типа, са различитим параметрима и за различите конфигурације ХПС [12], [18], [20], [38].



Методе засноване на фази-логици (енг. *fuzzy-logic*) [9], [39]–[42] припадају скупу директно примењивих метода, као и ECMS [43]–[48] (енг. *Equivalent Consumption Minimization Strategy*). Код ове друге методе, врши се оптимизација управљања радом погонских машина у сваком тренутку, разматрајући утрошак горива мотора СУС за сваки временски тренутак и тзв. "еквивалентни утрошак горива алтернативног енергетског акумулатора"

(електрохемијске батерије, хидро-пнеуматског акумулатора, итд.). Наиме, за свако коришћење секундарног акумулатора енергије, потребно је размотрити утрошак горива за поновно враћање стања напуњености акумулатора на претходно стање, узимајући у обзир и све трансформације снага и одговарајуће губитке (од МСУС до алтернативног генератора енергије, до акумулатора енергије па до алтернативног погонског мотора).

#### 2.3.2 Предиктивне методе за оптимизацију управљања ХПС

Другу велику групу примењивих метода за управљање хибридним погонским системима чине методе које се заснивају на предвиђању будућих стања система на основу тренутних и претходно успостављених, које даље омогућавају примену оптимизације управљања у реалном времену. У ове методе спадају опште MPC (енг. Model-Predictive Control) [49]-[51], које решавају проблем оптимизације уз коришћење математичких модела погонског система у коначном временском хоризонту (за разлику од ДП). Стохастичко динамичко програмирање (енг. Stochastic Dynamic Programming) [52], [53], [34], [54], [55] и остале методе које користе Марковљеве ланце такође припадају тој групи метода. Марковљев ланац је стохастички модел који предвиђа будуће стање система искључиво на основу тренутног. Они се најчешће користе тако да се процењују вероватноће будућих вредности брзине кретања возила, на основу којих се могу проценити и захтеви у погледу испорученог ефективног обртног момента погонском систему. Поред тога што су перформансе оптимизације ових метода понекад и знатно слабије од референтних, непримењивих, неке од њих релативно лако превазилазе могућности практичне примене на управљачким системима услед превеликих захтева у погледу прорачунске снаге процесора.

## 2.3.3 Предложена метода за оптимизацију функционалних и управљачких параметара ХПС

Идеја ове докторске дисертације јесте да се кроз експериментално и теоријско истраживање омогући утврђивање утицаја функционалних параметара хидропнеуматског акумулатора на стање ХПС и испита могућност примене метода заснованих на неуронским мрежама [56] у процесу извођења и примене оптималног алгоритма управљања. Наиме, на основу података прикупљених са возила јавног градског превоза које саобраћа у реалним експлоатационим условима, могуће је формирати калибрисане моделе конвенционалног погонског система и надаље их надоградити моделима алтернативних погонских машина и додатног акумулатора енергије и тако формирати моделе ХПС за разматрано возило. Формирањем аналитичког модела хидро-пнеуматског акумулатора, омогућено је утврђивање и детаљна анализа утицаја притиска преднапрезања (масе гаса), радне запремине и масе еластомерне пене на степен корисности самог акумулатора, као и на хибридни погонски систем као целину, кроз разматрање укупног остваривог потенцијала у апсорбовању и складиштењу енергије кочења.

На основу свих ових модела, као и коришћењем различитих класа возних циклуса (за различите услове саобраћаја, попут оптерећења трасе аутобуса, броја путника у аутобусу, итд.) добијених током експерименталног истраживања, могуће је извршити глобалну

оптимизацију управљања за различите услове саобраћаја употребом ДП. Тај скуп података би се даље употребио за тренирање неуронских мрежа са циљем извођења управљачког алгоритма. Крајњи циљ дисертације је утврђивање остваривог учинка ХХПС у реалним експлоатационим условима.

## 3 Математичко моделирање хибридних погонских

#### система

У овом поглављу ће бити представљен математички модел ХПС возила јавног градског превоза којим ће се вршити нумеричке симулације које су предмет ове дисертације. У основи, математички модел једног система, процеса, машине или феномена представља систем једначина који довољно верно описује одређено понашање система на основу улазних величина, као и тренутног стања. О самом концепту модела, методологији и емпиријској валидацији математичког моделирања више информација може се наћи у [57]. Према захтевима који су постављени пред одређеним математичким моделом, они могу бити мање или више сложени, могу их чинити диференцијалне или алгебарске једначине, итд.

У првом делу овог поглавља описане су методологија и процедуре експерименталног испитивања, као и сам аквизициони систем који је био коришћен за ту сврху.

У другом делу поглавља су представљени резултати добијени обрадом снимљених података. Конкретно, представљена је метода, као и резултати анализе параметара возног циклуса у погледу утицаја саобраћајних застоја на одвијање превоза, ради формирања различитих еквивалентних класа возних циклуса.

Трећи део предметног поглавља тиче се идентификације параметара модела погонског система на основу обрађених података са експерименталног испитивања. У овом делу представљен је модел конвенционалног погонског система возила јавног градског превоза, као и процедура његове калибрације.

На крају, приказани су математички модели АПС који чине додатну погонску машину (електрични мотор/генератор и хидраулични мотор/пумпа), као и модели акумулатора енергије који за циљ имају да прикупљају енергију кочења возила (електрични суперкондензатори и хидро-пнеуматски акумулатор). Ови елементи чине окосницу надградње која омогућује разматрање потенцијалних перформанси хибридног погонског система примењеног на калибрисаном моделу конвенционалног погонског система.

## 3.1 Методологија и процедуре испитивања

У циљу прикупљања података за калибрацију симулационих модела погонских система и добијања репрезентативних возних циклуса у стварним експлоатационим условима, спроведено је испитивање на једном аутобусу јавног градског превоза у Београду. Испитивање је извршено на аутобусу Икарбус ИК206 (слика 3.1) са МАN шестоцилиндарским, турбопуњеним дизел-мотором радне запремине 10,5 dm<sup>3</sup> и аутоматским мењачем Voith 864.5 [58]. Аутобус је саобраћао на линији 83, на релацији Црвени крст – Земун (Бачка) – Црвени крст.


Слика 3.1: Зглобни средњеподни аутобус Икарбус ИК 206 [59]

### 3.1.1 Поставка експеримента

На предметном возилу користи се CAN мрежа (енг. Controller Area Network) путем које сви погонски контролери и остали модули на возилу међусобно комуницирају. Примењен је протокол вишег нивоа - SAE протокол J1939 [60], који се углавном користи код тешких возила. Диспозиција типичне J1939 мреже приказана је на слици 3.2. Модули који управљају појединачним под-системима међусобно су повезани и могу размењивати поруке од важности за функционисање целог система.



Слика 3.2: Типична диспозиција ]1939 мреже [61]

На слици 3.3 приказана је спецификација проширене CAN поруке са описом значења доминантних и рецесивних битова. Опширније информације могу се наћи у ISO стандардима [62], [63].

		Arbitration field					Co	ontr	ol field			
[	SOF	ldentifier	SRR	IDE	Identifier	RTR	r1	r0	DLC	Data	CRC	ACK
	d	11 bits	r	r	18 bits				4 bits	0–8 bytes		

SOF: Почетак поруке (енг. Start Of Frame), увек доминантан бит,

RTR: Захтев за даљински пренос (eng. Remote Transmission Request), доминантан бит за стандардну поруку, рецесивни бит за даљинску,

IDE: Проширен идентификатор (енг. Identifier Extension), доминантан бит за стандардну поруку, рецесивни бит за проширену,

DLC: Код дужине података (енг. Data Length Code),

r0, r1: Резервисани битови,

SRR: Заменски даљински захтев (енг. Substitute Remote Request), увек рецесивни бит како би се осигурао пренос стандардне поруке у случајевима када и проширена има исти идентификатор.

#### Слика 3.3: Спецификација проширене CAN поруке ("Extended")

Једна од одлика овог протокола јесте могућност слања поруке чија величина превазилази 8 бајтова употребом такозваног ТР ("Transport Protocol"). У поређењу са стандардним CAN протоколима, поменути стандард предвиђа коришћење углавном порука намењених емитовању ("broadcast" поруке), тако да чворишта могу добити и користити информације од било ког другог модула на возилу.



Слика 3.4: Диспозиција аквизиционог система (исправити слику – мерење масе возила)

За потребе спровођења поменутог испитивања, развијен је аквизициони систем (слика 3.4) заснован на платформи NI CompactRIO [64]. Коришћен је real-time микроконтролер NI cRIO-9025 (слика 3.5) [65] са процесором фреквенције 800 MHz, 512 MB DRAM и уграђеним складиштем од 4 GB. Контролер је био повезан са 8-слотним кућиштем NI cRIO-9118 FPGA (слика 3.6) [66] (Virtex-5 LX110) у који је био убачен САN модул NI 9853 (слика 3.7) [67], [68]. Поред поменутих елемената и модула, употребљен је и GPS пријемник Garmin 18x [69] фреквенције 5 Нz ради бележења позиције возила и снимања возних циклуса током експлоатације.



Слика 3.5: NI cRIO-9025 микроконтролер [70]







Слика 3.7: NI 9853 САN модул [72]

Направљене су две апликације у оквиру решења за аутономну аквизицију података. Обе апликације написане су у оквиру програмског окружења NI LabVIEW [73]. Главна апликација, задужена за прикупљање података користи елементе NI-CAN Frame API палете [68] за прикупљање целокупног саобраћаја са J1939 CAN мреже. Један њен део, смештен у FPGA, служи само за прикупљање CAN порука са модула и њихово спровођење у FIFO бафер. Други део апликације налази се на самом контролеру и има за циљ премештање порука из бафера у меморију и складиштење саобраћаја. Напомиње се да је сам CAN модул био подешен да функционише на, за J1939 стандардних 250 kbit/s. Стандардне NMEA (према стандарду NMEA 0183 [74]) поруке са GPS пријемника прикупљане су путем серијског интерфејса на контролеру. Употребљени су елементи у оквиру палете алата NI-VISA [75] у програмском окружењу LabVIEW за успостављање везе са пријемником. Поруке су складиштене у ASCII формату.

У циљу праћења рада аквизиционог уређаја, направљена је и једна мониторингапликација (слика 3.8) за исписивање тренутних вредности најважнијих параметара погонског система. Опис целокупног аквизиционог система представљен је у [76].



Слика 3.8: Предњи панел апликације за праћење експеримента

Експеримент је трајао укупно пет дана, након којих је прикупљено преко 8 GB података.

Саобраћај који се одвијао на CAN мрежи складиштен је у NI-CAN Logfile формату (*.ncl* датотеке), док су поруке са GPS пријемника бележене у одговарајуће ASCII датотеке. Главна апликација која је била задужена за рад аквизиционог уређаја била је осмишљена на начин да се процес прикупљања података аутоматски покрене приликом давања контакта на возилу.

Табела 3.1: Пример снимљене поруке са CAN мреже

Време (релативно)	Идентификација поруке ("Arbitration ID")	Број бајтова	Подаци (од 1. до 8. бајта)
270.706300	2CF00 400	8	F1 7D 88 30 11 FF 0 FF

На слици 3.9 приказан је извод из стандарда који се односи на поруку приказану у табели 3.1. На основу ових података, формирана је база спецификација свих канала доступних на

CAN магистрали. Даље су, уз помоћ NI DIAdem апликације, изведени сви сигнали прерадом снимљених *.ncl* датотека помоћу формиране базе канала. На тај начин, добијени су токови свих доступних параметара у функцији времена.

PGN 614	44	Electronic	Engine Controller 1	- EEC1
Engine relat	ted parameters			
Transmissio	on Repetition	engine sp	eed dependent	
Data Length	1:	8		
Data Page:		0		
PDU Forma	t:	240		
PDU Specif	ic:	4	PGN Supporting Information:	
Default Prio	rity:	3		
Parameter (	Group Number:	61444	(0xF004)	
Start Posit	ion Length	Paramete	r Name	SPN
1.1	4 bits	Engine Tor	que Mode	899
2	1 byte	Driver's De	mand Engine - Percent Torque	512
3	1 byte	Actual Eng	ine - Percent Torque	513
4-5	2 bytes	Engine Spe	eed	190
6	1 byte	Source Ad	dress of Controlling Device for Engine Control	1483
7.1	4 bits	Engine Sta	rter Mode	1675
8	1 byte	Engine Der	mand – Percent Torque	2432
		Слика 3.9	: Извод из SAE J1939 стандарда [60]	

Од доступних GPS реченица, бележене су само \$GPRMC поруке које садрже све потребне информације за потребе дефинисања возног циклуса (слика 3.10). Због велике осетљивости вучне силе на нагиб пута, потребно је бележити и надморску висину током извођења експеримента. Један од начина јесте и праћење осталих стандардних реченица које садрже тај податак. Међутим, током пробног експеримента је установљено да је прецизност тих сигнала недопустиво мала. Зато је одлучено да ће се искључиво мерити географска дужина и ширина и тек касније, посредно, доћи до вредности надморске висине дуж циклуса на основу које је коначно могуће одредити и нагиб пута. За те потребе употребљени су дигитални модели надморске висине (енг. *Digital Elevation Model*) [77], [78].

\$GPRM	\$GPRMC,110648.4,A,4446.25736,N,02031.20083,E,000.01,000.0,110514,004.0,E*5D						
:	1	110648	време				
:	2	A	валидност поруке – А-у реду, V-није у реду				
:	3	4446.25736	тренутна географска ширина				
	4	Ν	North-север/South-jyr				
!	5	02031.20083	тренутна географска дужина				
	6	E	East-исток/West-запад				
	7	000.01	брзина у чворовима				
:	8	000.0	курс				
	9	110514	ознака датума				
:	10	004.0	одступање				
:	11	E	East-исток/West-запад				
:	12	*5D	контролна сума				

Слика 3.10: Пример снимљене NMEA поруке са GPS пријемника

Траса од почетног до крајњег стајалишта је најпре подељена на 200 интервала исте дужине, на којима су осредњене вредности географске дужине и ширине. Те осредњене вредности су коришћене као улазни параметри за примењени модел надморске висине и тиме је добијено укупно 200 вредности надморске висине дуж трасе. Тако добијени ток је накнадно осредњен применом алгоритма кубног сплајна, након чега је извршено нумеричко диференцирање сигнала како би се израчунао ток нагиба пута. На слици 3.11 приказан је профил нагиба пута, као и профил надморске висине пута дуж разматраног возног циклуса на релацији Црвени крст – Земун (Бачка) – Црвени крст.



Слика 3.11: Нагиб пута и надморска висина за возни циклус у смеру 1

Узимајући у обзир методологију снимања и формирања датотека на аквизиционом уређају и праксу да се мотор на крајњим стајалиштима не искључује, није неочекивано што су снимљене датотеке неретко обухватале целодневне возне циклусе. Ради раздвајања појединачних возних циклуса од једног до другог крајњег стајалишта, узети су опсези координата географске дужине и ширине крајњих станица за све снимљене сирове возне циклусе. Ти подаци употребљени су за одређивање временских тренутака достизања крајњих стајалишта који уједно означавају и границе новоформираног циклуса. Паралелно са процесом раздвајања појединачних деоница циклуса, извршена је и синхронизација сета података добијених из управљачких јединица погонског система, GPS пријемника, као и података о тренутној маси возила који су добијени мерењем притиска у ваздушним јастуцима. Синхронизација времена на аквизиционом уређају, као и у снимљеним подацима који обухватају податке о тренутној маси возила извршена је са референтним временским током добијеним GPS пријемником. Провера синхронизације обављена је упоређивањем токова брзине кретања возила снимљених из управљачке јединице и GPS пријемника.

### 3.2 Возни циклуси

У овом одељку биће појашњене употребљене методе, као и резултати анализе снимљених возних циклуса.

Снимљено је укупно 36 возних циклуса у смеру 1 (Земун – Црвени крст) и 34 циклуса у смеру 2 (Црвени крст – Земун).

У табелама А.1 и А.2 приказане су апсолутне вредности параметара возних циклуса (средња брзина возила приликом кретања, средње убрзање и успорење током кретања, итд.) за смер 1 и 2, респективно. У табелама А.3 и А.4 дате су, поред времена почетка, краја и укупног трајања циклуса и вредности средњег квадратног одступања позитивног, негативног убрзања и масе возила.

Снимљени су сви карактеристични режими саобраћаја. Најраније започет возни циклус био је у 06:38, док је завршетак најкасније снимљеног циклуса био у 21:15. У смеру 1, потрошња горива од почетног до крајњег стајалишта кретала се у границама од 5,451 до 8,148 kg, док је за смер 2 тај опсег од 4,836 до 6,651 kg.



Слика 3.12: Зависност масе потрошеног горива у функцији средњег позитивног убрзања, средње брзине возила у фазама кретања, средње масе возила и укупног трајања циклуса за смер кретања 1

На слици 3.12 приказани су дијаграми који приказују зависност апсолутне потрошње горива за извођење циклуса у смеру 1 од средњих вредности позитивног убрзања возила, брзине возила током кретања (када је брзина већа од 0,01 m/s), масе возила, као и укупног трајања предметног циклуса. Примећује се позитивна корелација средњег позитивног убрзања и потрошње горива, што се може објаснити већом ангажованом снагом мотора. Такође, у условима великог оптерећења саобраћајница и застоја, карактеристичан је велики број заустављања и поновног убрзања возила, када се постижу и највеће вредности убрзања. Зато није неочекивано да су, у највећем броју случајева, високе вредности позитивног убрзања управо постигнуте код возних циклуса са најдужим трајањем. Што се тиче средње брзине возила у фазама кретања, приметна је негативна корелација са укупном потрошеном количином горива. Када су саобраћајнице проходне, аутобус постиже веће брзине кретања, трајање циклуса је смањено, заустављања и накнадна убрзања су ређа па је и потрошња горива мања. Корелација између средње масе возила и потрошње горива мање је изражена. Приметно је да су највеће вредности потрошње горива забележене за умерене вредности масе возила између 18 и 19 тона, док је најмања потрошња забележена за средњу вредност масе возила од око 19,5 тона. Што се укупног трајања возног циклуса тиче, приметна је позитивна корелација са потрошњом горива. Дуже трајање циклуса карактеристично је за отежане услове саобраћаја у вршном оптерећењу, када је средња брзина возила смањена и када је повећан број заустављања аутобуса.



Слика 3.13: Зависност масе потрошеног горива у функцији средњег позитивног убрзања, средње брзине возила у фазама кретања, средње масе возила и укупног трајања циклуса за смер кретања 2

На слици 3.13 приказани су дијаграми за случај кретања аутобуса у смеру 2. Закључци и анализа су истоветни анализи спроведеној за случај кретања возила у смеру 1.

Приказани параметри указују да су услови у којима саобраћа возило јавног градског превоза изузетно разноврсни. Са аспекта оптимизације хибридног погонског система, то представља изазов који је потребно решити како би циљеви хибридизације били испуњени. Ради оцењивања перформанси предложене методе оптимизације управљања радом ХПС, потребно је извршити класификацију возних циклуса у неколико категорија које ће обухватити све репрезентативне услове саобраћаја у граду.

Параметар који најбоље описује критеријум оптерећења у саобраћају јесте укупно трајање возног циклуса. За разматрани смер кретања возила, пређени пут је константан, па је време потребно за његово комплетирање пропорционално застојима на путу. У том смислу, извршена је најпре класификација циклуса према критеријуму укупног трајања у укупно три категорије. Границе категорија за смер кретања 1 и 2 израчунате су применом функције *discretize* у MATLAB-у *и* пприказане су у табели 3.2.

Табела 3.2: Границе категорија према критеријуму укупног трајања возног циклуса

Смер		Границе ка	тегорија [s]	
Смер 1	2100	2500	2900	3300
Смер 2	2000	2600	3200	3800

У оквиру ових категорија, извршена је додатна класификација према критеријуму средње брзине кретања возила како би се у оквиру већ успостављених категорија које су условљене условима на путевима извршила финија класификација према стилу вожње возача аутобуса и врсти застоја у саобраћају.

Границе категорија према критеријуму вредности средње брзине возила у фазама кретања израчунате су на исти начин као и за критеријум укупног трајања циклуса и дате су у табели 3.3.

Смер	Границе категорија			Границе категорија				Границе категорија				
	за најкраће циклусе		за циклусе средњих			за најдуже циклусе						
		[m	/s]		Т	рајањ	a [m/s	]		[m	/s]	
Смер 1	6,50	6,68	6,86	7,04	5,60	6,00	6,40	6,80	5,20	5,50	5,80	6,10
Смер 2	6,00	6,40	6,80	7,20	5,70	5,89	6,08	6,27	5,20	5,39	5,58	5,77

Табела 3.3: Границе категорија према критеријуму средње брзине приликом кретања возила

# 3.3 Идентификација система и калибрација модела конвенционалног погона

Ради формирања модела конвенционалног погонског система који ће бити верни физичком објекту, потребно је извршити процес калибрације, користећи базу прикупљених и обрађених података добијених у стварним возним и експлоатационим условима. Пошто је акценат у овом истраживању оптимизација потрошње горива, најважнији параметри које је потребно идентификовати јесу мапе специфичне ефективне потрошње горива и спољне брзинске карактеристике ефективног момента мотора. Обједињавањем расположивих канала погонске групе свих циклуса у једну целину (оне који су део *Electronic Engine Controller 1* – EEC1 и *Electronic Engine Controller 3* – EEC3 порука) и њиховом обрадом добијене су тражене мапе.

### 3.3.1 Формирање мапе специфичне ефективне потрошње горива

Направљена је МАТLAВ скрипта која изводи вредности из сета података погонске групе према унапред дефинисаним радним тачкама мотора. Радни опсег броја обртаја КВ МСУС (од 550 до 1900 min<sup>-1</sup>) подељен је на укупно 21 вредност (са кораком од 67,5 min<sup>-1</sup>), док су вредности средњег ефективног притиска узете у опсегу од нулте вредности до максималне за тај број обртаја мотора (према мапи спољне брзинске карактеристике мотора). Према тако добијеној матрици унапред дефинисаних радних тачака МСУС, прикупљени су радни режими из расположивог скупа са толеранцијом од  $\pm 10$  min<sup>-1</sup> за број обртаја КВ МСУС и  $\pm 0,2$  bar за вредности средњег ефективног притиска мотора. Динамички радни режими изузети су из ове анализе тако што се из вектора запреминског протока горива одстрањују режими код којих су централне разлике веће од 0,01 dm<sup>3</sup>/h и вредности веће од 0,01 kW за ток ефективне снаге мотора. Уколико је број детектованих радних тачака за разматрани радни режим већи од десет, спроводи се регресија тих података полиномом првог степена, уз примену локално пондерисаног,

робусног *bisquare* алгоритма [79], [80] којим се занемарује утицај вредности које одскачу од нормалних. За коначну меродавну вредност протока горива узима се она које се налази на половини интервала регресионог модела.

Ради формирања мапе специфичне ефективне потрошње горива за цело радно поље МСУС (слика 3.14), извршена је интерполација претходно добијених вредности применом Кригинговог алгоритма (*Kriging*) [81].



Слика 3.14: Идентификована мапа специфичне ефективне потрошње горива предметног МСУС

#### 3.3.2 Одређивање карактеристика преносника снаге

За одређивање карактеристика хидродинамичке спојнице, потребно је било обавити сличну идентификациону процедуру као и у претходном случају, али употребом других канала са J1939 мреже. Обухватајући све расположиве вредности добијене током аквизиције података, могуће је одредити зависност фактора капацитета хидродинамичке спојнице у функцији односа угаоних брзина хидродинамичке спојнице. Фактор капацитета дефинисан је као

$$K = \sqrt{10 \frac{n_{imp}^2}{T_{imp}}}, \qquad (3.1)$$

где је  $n_{imp}$  број обртаја улазног вратила спојнице, а  $T_{imp}$  је обртни момент на улазном вратилу хидродинамичке спојнице.

Анализом података идентификована је и карактеристика хидродинамичке спојнице у погледу степена пораста обртног момента у функцији односа угаоних брзина излазног и улазног вратила спојнице. Резултати идентификације параметара објављени су у [82].

# 3.3.3 Опис симулационог модела КПС и калибрација параметара коефицијента отпора котрљања возила

На слици 3.15 приказан је симулациони модел КПС у програмском окружењу AMESim.



Слика 3.15: Модел конвенционалног погонског система у програмском окружењу АMESim

За симулацију конвенционалног погонског система предметног аутобуса као и калибрацију возилских параметара попут коефицијента отпора котрљања и аеродинамичких губитака, коришћен је софтверски пакет за више-доменску симулацију LMS Imagine.Lab AMESim.

Иза модела аутобуса у AMESim-у налази се једначина Другог Њутновог закона:

$$\frac{dv_{v}}{dt} = \frac{1}{m_{v}} \cdot \left[ F_{dr} - \left( F_{b} + F_{res} \right) \cdot C_{stat} \right], \qquad (3.2)$$

где је  $C_{stat}$  коефицијент статичког трења који износи 1,2 када возило није у покрету. Вучна сила  $F_{dr}$  рачуна се помоћу једначине

$$F_{dr} = \frac{(T_2 + T_4)}{R_w}, \qquad (3.3)$$

где су  $T_2$  и  $T_4$  улазне вредности обртног момента (за предње и задње точкове, респективно) а  $R_w$  је радијус точка.

Поред повећања кинетичке и потенцијалне енергије возила, део енергије који потиче од погонског система користи се за убрзање ротационих делова који чине погонски систем. Сила инерције точкова рачуна се помоћу обрасца

$$F_{w} = \frac{\Theta_{w}}{R_{w}^{2}} \cdot \frac{dv_{v}}{dt}, \qquad (3.4)$$

где је  $\Theta_w$  укупни момент инерције ротационих делова ПС.

За поједностављен случај разматрања одсуства проклизавања пнеуматика на путу, може се израчунати утицај инерције точкова на укупну инерцију возила као

$$m_{w} = \frac{\Theta_{w}}{R_{w}^{2}}.$$
(3.5)

Сила кочења дефинисана је као

$$F_{b} = \frac{\left(T_{b,front} + T_{b,rear}\right)}{R_{w}}.$$
(3.6)

Укупна сила отпора узима у разматрање силу савладавања нагиба пута, аеродинамичке и отпоре котрљања:

$$F_{res} = F_{cl} + F_{aero} + F_{roll} = (m_{veh} \cdot g \cdot \sin[\arctan(0.01 \cdot \alpha)]) + \left(\frac{1}{2} \cdot \rho_{air} \cdot c_x \cdot S \cdot v_{veh}^2\right) + m_{veh} \cdot g \cdot (f + k \cdot v + w \cdot v^2)$$
(3.7)

где је  $\alpha$  нагиб пута у %, S је фронтална површина возила а f је константни коефицијент отпора котрљања, k је коефицијент сразмеран брзини кретања возила, а w је коефицијент отпора котрљања сразмеран квадрату брзине кретања возила.

Вредност момента који се користи за погон аутобуса добија се као излазна величина из компоненте *driver*, која је у основи PID контролер чији се излаз формира на основу вредности грешке у брзини кретања возила (разлика тренутне и жељене брзине кретања). Излаз из контролера прослеђује се до компоненте модела – управљачке јединице мотора, која шаље одговарајући сигнал оптерећења мотору СУС. Након тога, обртни момент из мотора се трансформише у мењачу и прослеђује моделу аутобуса. Са друге стране, команда кочења, која такође настаје у компоненти возача, прослеђује се директно предње точкове аутобуса. У AMESim модел примењени су идентификовани модели хидродинамичке спојнице (фактор капацитета и степен пораста притиска), као и правила промене степена преноса у мењачу. Закључавање хидродинамичке спојнице активира се при промени из првог у други степен преноса у мењачу.

Ради провере успешности обављене процедуре идентификације параметара система, као и због одређивања параметара губитака возила, извршена је калибрација модела формираног у симулационом окружењу AMESim. Извршена је калибрација коефицијената отпора котрљања смањивањем суме квадрата разлика између симулиране и стварно потрошене кумулативне потрошње горива. Употребљен је генетички алгоритам [83] јер омогућава конвергирање глобалном минимуму [84]. Генетички алгоритам припада класи оптимизационих метода проистеклих из области еволуционог рачунарства [85]. Имитацијом биолошких процеса природне селекције и репродукције, могуће је пронаћи минимум или максимум функције укрштањем "најспособнијих" кандидата решења, тзв. хромозома.

Типична процедура генетичког алгоритма [86] састоји се из избора почетне популације хромозома насумичним процесом. Након тога, врши се избор најспособнијих хромозома (кандидата решења) према критеријуму минимизације или максимизације разматране функције. Следи примена процеса раздвајања, тј. размене гена (кросинг-овера) и мутације. Кросинг-овер је феномен размене појединачних гена између два хромозома (родитеља, тј. хромозома из претходне генерације). Уколико је вероватноћа кросинг-овера 100%, потомство је у потпуности сачињено укрштањем појединачних хромозома. Са вероватноћом од 0%, потомство ће бити сачињено од непромењених хромозома из претходне генерације). Мутацијом се појединачни гени хромозома мењају, чиме се поспешује конвергирање глобалном решењу.

У спроведеном истраживању, употребљени су следећи параметри оптимизације: величина популације је 100, вероватноћа кросинг-овера је 60%, величина генерације је 20, са вероватноћом мутације од 10% и амплитудом од 0.6. Резултати оптимизације дати су у табели 3.4.

Табела 3.4: Резултати оптимизације параметара коефицијента отпора котрљања возила

Параметар коеф. отпора котрљања	Вредност
f [-]	0,01643
k [1/(m/s)]	0,0003147
$w [1/(m/s)^2]$	$1,515 \cdot 10-5$

Токови симулиране и снимљене потрошње горива дуж разматраног возног циклуса приказане су на слици 3.16.



Слика 3.16: Упоредни приказ снимљене и симулиране кумулативне потрошње горива дуж читавог циклуса

На слици 3.17 упоредно су приказани симулирани и снимљени ток брзине кретања возила за деоницу разматраног циклуса. Приметно је задовољавајуће слагање, што је

последица адекватног рада возачке компоненте симулације и прикладног управљања обртним моментом мотора.

На слици 3.18 упоредно су приказани симулирани и снимљени ток броја обртаја КВ мотора за једну деоницу једног од разматраних циклуса (*270 001\_05\_2*). Постигнуто је задовољавајуће слагање, иако одређених одступања у тренуцима промене степена преноса постоје. Разлике су присутне превасходно услед немогућности примене сложеног модела промене степена преноса коришћеног на конкретном погонском систему.



Слика 3.17: Упоредни приказ снимљене и симулиране брзине кретања возила



Слика 3.18: Упоредни приказ снимљеног и симулираног броја обртаја мотора

На слици 3.19 представљени су токови кумулативне потрошње горива забележене у току испитивања и оне добијене симулацијом конвенционалног погонског система на

разматраној деоници возног циклуса. Незнатне разлике јављају се у фазама убрзања возила, када су вредности угаоне брзине МСУС различите између физичког објекта и симулационог модела. Ипак, одступања су довољно мала за потребе спровођења анализа укупне потрошње горива конвенционалног погонског система и, напослетку, модела хибридног погонског система.



Слика 3.19: Упоредни приказ снимљене и симулиране потрошње горива дуж деонице разматраног возног циклуса

# 3.4 Математички модели алтернативних погонских система и акумулатора енергије

### 3.4.1 Модел хидрауличне машине

За потребе извођења симулација ХХПС, коришћен је модел хидрауличне машине (у даљем тексту ХМ) променљиве радне запремине, капацитета 250 сm<sup>3</sup>. У питању је аксијална клипна пумпа произвођача Rexroth, модел A4VSO [25], [87], [88]. Ова машина служи за прикупљање енергије кочења добијене смањењем кинетичке енергије возила (режим рада хидрауличне пумпе) и за сукцесивно покретање возила из места или за додатни погон уз МСУС (режим рада хидрауличног мотора).

Спрега ове машине са остатком ПС је изведена са преносним односом од 1,2 како би се радно поље XM прилагодило радном опсегу броја обртаја КВ МСУС.

Мапа ХМ дата је на слици 3.20.

На основу мапе пумпе, потребно је формирати комплетну радну мапу ради обављања нумеричких симулација и оптимизационих прорачуна. За те потребе, коришћен је модел хидрауличних машина [89]. Идеални запремински проток кроз пумпу или мотор може бити описан следећим обрасцем:

$$Q_i = x \,\omega \, D \,, \tag{3.8}$$

где је x однос тренутног и максималног капацитета машине,  $\omega$  је угаона брзина XM, док је D максимална радна запремина XM по радијану.





Запремински степен корисности пумпе дефинисан је као:

$$\eta_{v,p} = \frac{Q_e}{Q_i}, \qquad (3.9)$$

где је  $Q_e$  стварни проток кроз XM.

За случај разматрања хидрауличног мотора, разломак је инверзан:

$$\eta_{\nu,m} = \frac{Q_i}{Q_e} \,. \tag{3.10}$$

Претходно описани коефицијенти могу се изразити и уз помоћ ламинарног и турбулентног коефицијента цурења:

$$\eta_{\nu,p} = 1 - \frac{C_s}{xS} - \frac{\Delta p}{\beta} - \frac{C_{st}}{x\sigma}, \qquad (3.11)$$

где су  $C_s$  и  $C_{st}$  ламинарни и турбулентни коефицијенти цурења, респективно а  $\beta$  је модул стишљивости уља. Разлика притиска на потису и усису XM је означена са  $\Delta p$ . Бездимензионе величине S и  $\sigma$  дефинисане су као:

$$S = \frac{\mu \, \omega}{\Delta \, p} \,, \tag{3.12}$$

$$\sigma = \frac{\omega D^{\frac{1}{3}}}{\left(2\frac{\Delta p}{\rho}\right)^{\frac{1}{2}}}.$$
(3.13)

За хидраулични мотор, запремински степен корисности је

$$\eta_{\nu,m} = \frac{1}{1 + \frac{C_s}{xS} + \frac{\Delta p}{\beta} + \frac{C_{st}}{x\sigma}}.$$
(3.14)

Обртни момент потребан за рад идеалне пумпе добија се као

$$T_i = x \cdot \Delta p \cdot D . \tag{3.15}$$

Степен корисности пумпе дат је односом идеалног и стварно потребног обртног момента:

$$\eta_{t,p} = \frac{T_i}{T_e}, \qquad (3.16)$$

где је  $T_e$ ефективна вредност обртног момента. Степен корисности XM у режиму рада мотора је:

$$\eta_{t,m} = \frac{T_e}{T_i} \,. \tag{3.17}$$

Увођењем величина хидродинамичког отпора, образац 3.16 може се изразити и као:

$$\eta_{t,p} = \frac{1}{1 + \frac{C_v S}{x} + \frac{C_f}{x} + C_h x^2 \sigma^2},$$
(3.18)

док је за случај рада хидрауличног мотора

$$\eta_{t,p} = 1 - \frac{C_v S}{x} - \frac{C_f}{x} - C_h x^2 \sigma^2.$$
(3.19)

Коефицијенти  $C_{\rm v}$ ,  $C_{\rm f}$  и  $C_{\rm h}$  представљају вискозни, фрикциони и хидродинамички отпор.

Користећи претходно описани модел хидрауличних машина и податке произвођача за изабрану пумпу, формирана је комплетна мапа радних карактеристика.



### 3.4.2 Модел хидро-пнеуматског акумулатора

Код XXIIC, складиштење енергије врши се помоћу хидро-пнеуматског акумулатора. Током фаза кочења возила, хидраулична пумпа потискује уље у акумулатор, у коме се сабија азот који се налази унутар меха. Ова енергија се користи приликом сукцесивног погона аутобуса, где се притисак азота користи за потискивање уља из акумулатора у хидраулични мотор који затим енергију предаје погонском систему. Комплетним потискивањем уља из акумулатора, мех унутар њега заузима максималну могућу запремину и притисак азота опада. Тиме се енергетски ниво напуњености хидропнеуматског акумулатора спушта на минималних 0% и припрема за наредну фазу кочења.

Значајан удео енергије који се предаје акумулатору, реда величине неколико десетина процената, расипа се преносом топлоте са гаса на зидове акумулатора и на крају на околину. Овај губитак може бити ублажен убацивањем у акумулатор пене од еластичних полимера (еластомерна пена) коју карактеришу високе вредности специфичне површине и специфичне топлоте. На тај начин, могуће је смањити амплитуде промене температуре изазване сукцесивним сабијањем и ширењем гаса и тако знатно повећати степен корисности хидро-пнеуматског акумулатора.

У поређењу са електрохемијским батеријама, хидро-пнеуматске акумулаторе карактеришу висока специфична снага и мала специфична енергија. Висока специфична снага чини их погодним за примену код тешких возила који саобраћају у условима учесталих успорења и убрзања. Са друге стране, ниска специфична енергија представља велики недостатак ових енергетских акумулатора јер им ограничава потенцијал

37

рекуперације енергије кочења и радијус кретања, тј. дужину дистанце на којој се погон обезбеђује из АПС и представља изазов у погледу оптимизације потрошње горива.

Коришћен је модел хидро-пнеуматског акумулатора са две независно променљиве. Прва променљива стања јесте температура гаса и она је изведена из једначине енергије [89]:

$$\left(\tau + \frac{m_f c_f}{hA_w}\right) \frac{dT}{dt} + T = T_w - \frac{T \tau}{c_v} \left(\frac{\partial p_g}{\partial T}\right) \frac{dv}{dt}, \qquad (3.20)$$

где су:

*m*<sub>f</sub> маса еластомерне пене,

*с*<sub>*f*</sub> специфични топлотни капацитет еластомерне пене,

*h* коефицијент преноса топлоте,

*A*<sub>w</sub> укупна површина зидова хидро-пнеуматског акумулатора,

Т температура гаса (азота),

*T*<sub>w</sub> температура зидова акумулатора,

*С*<sub>v</sub> специфични топлотни капацитет гаса (азота),

 $p_{q}$  притисак гаса (азота),

v специфична запремина гаса (азота),

*m*<sub>*a*</sub> маса гаса (азота) у акумулатору,

док је

$$\tau = \frac{m_g c_v}{h A_w} \tag{3.21}$$

термална временска константа [90]. Она представља време које протекне до постизања 63,2% од стационарне вредности температуре (или притиска) током изохорског хлађења након одскочне промене запремине гаса. Због изразито високих вредности притиска у акумулатору, азот се не може сматрати идеалним гасом. Због тога је коришћен модел реалног гаса према моделу Бенедикт-Веб-Рубин. Једначина стања реалног гаса према поменутом моделу може се написати као:

$$p_{g} = \frac{RT}{v} + \frac{1}{v^{2}} \left( B_{0}RT - A_{0} - \frac{C_{0}}{T^{2}} \right) + \frac{bRT - a}{v^{3}} + \frac{a \,\alpha}{v^{6}} + \frac{c}{v^{3}T^{2}} \left( 1 + \frac{y}{v^{2}} \right) \exp^{-y/v^{2}}, \tag{3.22}$$

где је R гасна константа, а a,  $A_0$ , b,  $B_0$ , c,  $C_0$ ,  $\alpha$  и  $\gamma$  су одговарајући коефицијенти за азот преузети из [91]. Комбиновањем претходне две једначине, могуће је доћи до следећег, коначног израза за диференцијалну једначину температуре гаса:

$$\left(1 + \frac{m_f c_f}{m_g c_v}\right) \frac{dT}{dt} = \frac{T_w - T}{\tau} - \frac{1}{c_v} \left\{\frac{RT}{v} \left(1 + \frac{b}{v^2}\right) + \frac{1}{v^2} \left(B_0 RT + \frac{2C_0}{T^2}\right) - \frac{2c}{v^3 T^2} \left(1 + \frac{y}{v^2}\right) \exp^{-y/v^2}\right\} \frac{dv}{dt} .$$
 (3.23)

Друга променљива стања, специфична запремина, изведена је из једначине континуитета

$$\frac{dv}{dt} = \frac{Q_e}{m_g}, \qquad (3.24)$$

где је  $Q_e$  запремински проток хидрауличне пумпе/мотора, а  $m_g$  је маса гаса у хидропнеуматском акумулатору.

За потребе примене овог математичког модела хидро-пнеуматског акумулатора у оквиру спровођењу процеса оптимизације ДΠ. алгоритма намењеног извршена ie дискретизација претходно описаних диференцијалних једначина. Систем дискретизованих једначина написан је применом методе Рунге-Кута (Runge-Kutta) 4. реда [92].

### 3.4.3 Модел ЕМ за ЕХПС

Поред модела XXПС, формиран је и један ЕХПС који користи искључиво ултракондензаторе за складиштење енергије.



Слика 3.23: Мапа електричне машине

Коришћен је електрични мотор/генератор номиналне снаге 175 kW који је постављен између хидродинамичке спојнице и самог мењача са редукцијом од 3,5. Максимални обртни момент износи 500 Nm и постиже се до 3000 min<sup>-1</sup>, док се максимална снага постиже на 4400 min<sup>-1</sup>. На слици 3.23 приказана је мапа спољне брзинске карактеристике обртног момента ЕМ која је коришћена у симулацији ЕХПС.

### 3.4.4 Модел акумулатора енергије за ЕХПС

За процену потенцијалних уштеда у потрошњи горива ПС које би биле омогућене применом ЕХПС, размотрен је акумулаторски систем заснован на примени

ултракондензатора, тј. електростатичких двослојних кондензатора. На слици 3.24 приказан је шематски приказ електричног модела ултракондензатора, који се може представити као кондензатор и редно везан отпорник, којим су представљени електрични губици ултракондензатора (слика 3.24).



Слика 3.24: Поједностављен електрични модел ултракондензатора [93]

Неколико конфигурација ултракондензатора је коришћено ради спровођења анализе утицаја повећања енергетског капацитета складиштења енергије на уштеду у потрошњи горива. Основни елемент електричног енергетског акумулатора чини модул Maxwell ВМОD0063 P125 [94] са номиналним напоном од 125 V. Ултракондензатори су повезани са електричном машином путем претварача, чији је задатак да прилагоди променљив напон ултракондензаторских модула фиксном излазном напону који је прилагођен електричном мотору/генератору. Претпостављен је константан степен корисности претварача од 90%. У табели 3.5 приказане су електричне карактеристике разматраних Удвостручавањем конфигурација ултракондензатора. броја серијски повезаних кондензатора, ефективна (укупна) капацитивност дели се са два, док се номинални напон удвостручује. С обзиром на то да је енергетски капацитет кондензатора пропорционалан капацитивности и квадрату вредности напона, потенцијал складиштења енергије се повећава. Предност серијске везе ултракондензатора огледа се у повећању номиналног напона, што погодује спрезању са електричним моторима/генераторима. Недостатак се огледа у повећању укупне електричне отпорности модула.

Конфигурација	Капацитивност	Електрична	Номинални	Потенцијал		
	[F]	отпорност [m $\Omega$ ]	напон	складиштења		
				енергије (50% до		
				100% SOC) [MJ]		
1 модул	63	18	125	0.37		
2 модула/серијски	31.5	36	250	0.74		
3 модула/серијски	21	54	375	1.11		
4 модула/серијски	15.75	72	500	1.48		
5 модула/серијски	12.6	90	625	1.85		
6 модула/серијски	10.5	108	750	2.22		

Табела 3.5: Електричне карактеристике разматраних конфигурација ултракондензатора

Напон отвореног кола може се изразити као однос количине наелектрисања и капацитивности ултракондензатора:

$$U_{oc} = \frac{Q_{uc}}{C_{uc}} \,. \tag{3.25}$$

Струја кроз ултракондензатор може се израчунати као однос снаге и напона ултракондензатора:

$$I_{uc} = \frac{P_{uc}}{U_{uc}} \,. \tag{3.26}$$

Напон ултракондензатора једнак је збиру напона отвореног кола (напон ултракондензатора када нема оптерећења, односно електричне струје) и пада напона на отпорнику:

$$U_{uc} = U_{oc} - R_{uc} I_{uc} , \qquad (3.27)$$

где су  $R_{SC}$  и  $I_{SC}$  отпорност и јачина електричне струје кроз ултракондензатор, респективно.

Комбиновањем једначина 3.26 и 3.27 може се добити израз за струју кондензатора:

$$R_{uc}I_{uc}^{2} - U_{oc}I_{uc} + P_{uc} = 0.$$
(3.28)

Вредност електричне струје се може добити решавањем квадратне једначине:

$$I_{uc} = \frac{U_{oc} - \sqrt{U_{oc}^2 - 4R_{uc} \cdot P_{uc}}}{2R_{uc}} \,. \tag{3.29}$$

Напон ултракондензатора може се добити на сличан начин, решавањем квадратне једначине која описује везу између напона, напона отвореног кола, снаге и електричног отпора ултракондензатора. Једначина напона рачуна се као:

$$U_{uc} = \frac{U_{oc}}{2} + \frac{1}{2} \frac{\sqrt{U_{oc}^2 - 4R_{uc} \cdot P_{uc}}}{2}.$$
(3.30)

Стање ЕХПС који употребљава ултракондензаторе као акумулатор енергије може се описати диференцијалном једначином стања напуњености ултракондензатора:

$$\frac{dSOC}{dt} = \frac{-I_{uc}}{Q_{max}},$$
(3.31)

где су  $Q_{max}$  и SOC максимална количина наелектрисања за разматрани ултракондензатор и његово стање напуњености (енг. State-Of-Charge), респективно.

# 4 Оптимизација функционалних и управљачких

# параметара хибридних погонских система

У овом поглављу биће речи о методи и процедури, као и резултатима оптимизације управљачких и функционалних параметара једног ПХПС намењеног погону возила јавног градског саобраћаја. Најпре ће се дефинисати проблем оптимизације система, након чега ће се приказати основе ДП и сама имплементација методе у MATLAB окружење. На крају, биће приказани и коментарисани гранични услови и резултати прорачуна.

# 4.1 Дефиниција проблема оптимизације

За формулисање одређеног проблема оптимизације потребно је [95]:

- 1. Математички модел разматраног процеса,
- 2. Дефиниција граничних услова,
- 3. Дефиниција критеријума учинка.

За променљиве стања  $x_1(t), x_2(t), ..., x_n(t)$  које описују разматрани процес и управљачке улазе  $u_1(t), u_2(t), ..., u_m(t)$  у временском тренутку t, систем се може описати са n диференцијалних једначина првог реда:

$$\dot{x}_{1}(t) = a_{1}(x_{1}(t), x_{2}(t), ..., x_{n}(t), u_{1}(t), u_{2}(t), ..., u_{m}(t), t) 
\dot{x}_{2}(t) = a_{2}(x_{1}(t), x_{2}(t), ..., x_{n}(t), u_{1}(t), u_{2}(t), ..., u_{m}(t), t) 
\cdot ..., \\\dot{x}_{3}(t) = a_{3}(x_{1}(t), x_{2}(t), ..., x_{n}(t), u_{1}(t), u_{2}(t), ..., u_{m}(t), t)$$

$$(4.1)$$

где је *a<sub>i</sub>*, у општем случају, нелинеарна функција стања система, управљачких улаза и времена.

Ако се уведе вектор променљивих стања система као:

$$\mathbf{x}(t) = \begin{bmatrix} x_{1}(t) \\ x_{2}(t) \\ \vdots \\ \vdots \\ x_{n}(t) \end{bmatrix}, \qquad (4.2)$$

и вектор управљачких улаза система:

$$\boldsymbol{u}(t) = \begin{bmatrix} u_{1}(t) \\ u_{2}(t) \\ \vdots \\ \vdots \\ u_{m}(t) \end{bmatrix}, \qquad (4.3)$$

једначине стања система могу се написати у следећем облику:

$$\dot{\mathbf{x}} = \boldsymbol{a}(\mathbf{x}(t), \boldsymbol{u}(t), t). \tag{4.4}$$

Гранични услови могу се поставити за променљиве стања и улазне променљиве система и могу бити задате као једнакости (најчешће за дефинисање почетних и коначних услова система), неједнакости (за, на пример, ограничавање опсега улазних променљивих) и могу бити исказане и као изрази који обухватају и интеграле променљивих система.

За потребе одређивања перформанси разматраног система, уводи се критеријум учинка система, који ће процесом оптимизације бити минимизован (односно максимизован). Општи облик учинка система је [95]:

$$J = h(\mathbf{x}(t_f), t_f) + \int_{t_0}^{t_f} g(\mathbf{x}(t), \mathbf{u}(t), t) dt, \qquad (4.5)$$

где су h и g скаларне функције, а  $t_0$  и  $t_f$  представљају почетно и крајње време, респективно.

Проблем оптимизације система подразумева проналажење вектора дозвољених улаза **и** који проузрокује кретање система дуж допуштене путање **x** које минимизује критеријум учинка J.

# 4.2 Динамичко програмирање

Принцип који стоји иза концепта ДП као методе за решавање проблема оптимизације система јесте принцип оптималности који, према Белману (*Bellman*) гласи [35]:

- Оптимални закон управљања има својство да, за било које стање система и улаз
- у почетном тренутку, даје оптималан след одлука за стање које проистиче из
- иницијалног тренутка.

Из овог исказа већ се може интуитивно наслутити сам метод ДП који се огледа у оцењивању критеријума учинка система дуж свих допуштених вредности променљивих стања и улаза система. Наиме, оптимално управљање, у општем случају, може се представити вектором управљачких величина које су функција вектора стања и времена:

$$\boldsymbol{u_{opt}} = \boldsymbol{f}(\boldsymbol{x}(t), t) \,. \tag{4.6}$$

Дакле, оптималан модел управљања је функција која одређује одлуку која ће минимизовати критеријум учинка система у тренутку *t* за одређено стање система у том тренутку. Начелно, модел управљања може бити променљив, те је приказан аргумент времена у функцији.



динамичког програмирања

Динамичко програмирање је нумеричка метода која се користи за решавање проблема оптимизације разлагањем више-стадијумског проблема одлучивања у мање целине и рекурзијом. Креће се од коначног времена и унапред дефинисаног стања система у том тренутку и одређује оптимална одлука у стадијуму који претходи коначном. Дискретизацијом простора стања добија се комбинована мрежа време-стање у чијим чвориштима се израчунава учинак преласка из датог у следећи стадијум, за све разматране и допуштене вредности управљачких улаза, разматрајући граничне услове система. За сва дискретизована и разматрана стања система у одређеном тренутку постоји идеална путања (са најбољим учинком) од тог стања до коначног. Идући уназад, оптимална одлука се може одредити за сваку комбинацију стадијум-стање која ће довести стање система из тренутне тачке у захтевано коначно, минимизирајући критеријум учинка. Долазећи до иницијалног стадијума, тј. почетног тренутка, добијају се матрице оптималног управљања и учинка (односно утрошка ресурса) до одредишта за свако стање система (енг. *cost-to-go* [96], [97]).

На слици 4.1 приказана је упрошћена шема стања система. Стања за почетни и крајњи тренутак су у потпуности дефинисана. Свака дуж од почетног до разматраних стања у неком тренутку t приказује утрошак датог, једно-стадијумског преласка стања система. Криве приказују укупни, минимални трошак преласка из стања у неком тренутку t до коначног стања система и обухватају све стадијуме од тренутног до крајњег. За приказани систем, јасно је да је оптимално управљање оно које ће систем превести из почетног до крајњег стања преко путање која је подебљана (укупан утрошак 6,15).

Математички, претходно изнесено се може изразити следећом рекурзијом:

$$J_{N-K,N}^{*}(\boldsymbol{x}(N-K)) = \min_{\boldsymbol{u}(N-K)} \left\{ g_{D}(\boldsymbol{x}(N-K), \boldsymbol{u}(N-K)) + J_{N-(K-1),N}^{*}(\boldsymbol{a}_{D}(\boldsymbol{x}(N-K), \boldsymbol{u}(N-K))) \right\}$$
(4.7)

Познајући  $J_{N-(K-1),N}^*$ , оптималну цену за одлуку у стадијуму K-1, може се одредити  $J_{N-K,N}^*$ , оптимални учинак система за одлуку у стадијуму K, са одговарајућим оптималним улазима система. Један од недостатака методе ДП, поред немогућности

директне примене у реалном времену, јесте и њено прорачунско оптерећење. Наиме, са повећањем броја стања система, експоненцијално расте време извршења оптимизације.

У овој дисертацији оптимизована је расподела оптерећења између примарне и секундарне погонске машине ПХПС. Удео енергетског доприноса алтернативне погонске машине (електричног мотора/генератора или хидрауличног мотора/пумпе) у укупној погонској енергији за позитивне вредности вучне силе и удео секундарне машине у укупној енергији кочења током фаза негативне вучне силе користи се као управљачки параметар оптимизације. Оптимизације су спроведене за различите параметре АПС и на тај начин се посредно долази и до закључака у вези са оптималним функционалним параметрима ХПС.

Коришћена је генеричка имплементација методе ДП у МАТLАВ-у [17], [98].

У наставку ће бити описани оптимизациони прорачуни једног ЕХПС који користи ултракондензаторе и једног ХХПС намењеног погону возила јавног градског саобраћаја. Анализираће се резултати прорачуна и на крају ће бити изведени закључци.

## 4.3 Електрични хибридни погонски систем

За одређивање оптималних управљачких и функционалних параметара ХПС базираног на употреби ултракондензатора, формиран је калибрисани модел погонског система који је прилагођен употреби у оквиру оптимизационих прорачуна применом динамичког програмирања. Извршена је дискретизација једначине стања напуњености ултракондензатора (3.31). Модели погонске машине као и акумулатора приказани су у поглављу 3.4.

Вредности калибрисаних параметара у вези са аеродинамичким и отпорима котрљања аутобуса имплементирани су у оквиру симулације која је прилагођена примени у оквиру оптимизационе процедуре. Такође, параметри возног циклуса као што су брзина кретања возила, убрзање, нагиб пута, маса путника и степен преноса уврштени су у симулацију. Модели компоненти ПС (поглавље 3.4), попут МСУС (мапа специфичне ефективне потрошње горива), електричног мотора/генератора (мапа степена корисности и спољне брзинске карактеристике ефективног момента), преносног механизма (карактеристике хидродинамичке спојнице, степена преноса, итд.), као и акумулатора енергије примењени су у поменутој симулацији. За све симулације ЕХПС, коришћен је возни циклус интерне ознаке: 270 001\_05\_2.

Недостатак динамичког програмирања, поред већ побројаних, јесте и немогућност оптимизације функционалних параметара модела ХПС. Због тога, неколико независно променљивих је уведено у симулацију и извршена је серија оптимизација. Параметри попут величине ЕМ, преносног односа између ЕМ и мењача, капацитета акумулатора енергије и максимално дозвољене вредности електричне струје кроз систем мењани су како би се посредно дошло до оптималне конструкције ЕХПС за дато возило и возни циклус. Вредности тих променљивих дати су у табели 4.1. Треба напоменути да је параметар величине ЕМ фактор којим се множи обртни момент ЕМ приказане на слици 3.23. Мапа степена корисности ЕМ је непромењена, тако да се пол економичности постиже при нижим вредностима обртног момента у поређењу са референтним случајем (када је параметар *motsize* једнак 1,0).

Фунцкионална променљива	Име	Вредност
Преносни однос између ЕМ и мењача [-]	reductor	2,0; 3,0; 4,0
Величина ЕМ [-]	motsize	0,4; 0,6; 0,8; 1,0
Број ултракондензаторских модула [-]	accusize	2; 3; 4; 5; 6
Макс. вредност јачине ел. струје кроз систем [А]	accucurrent	300; 500; неограничено

Табела 4.1: Преглед функционалних променљивих за ЕХПС



Резултати оптимизације приказани су у функцији броја ултракондензаторских модула за различите вредности параметара величине ЕМ и за променљиве вредности максимално дозвољене јачине електричне струје система на сликама 4.2 до 4.4. Референтна вредност потрошње горива износи 5,501 kg (измерена вредност потрошње за разматрани возни циклус) и резултати приказују релативно смањење потрошње горива постигнуте након извршене оптимизације управљачких параметара. За поменуте резултате, вредност преносног односа између ЕМ и мењача била је 3,0.

Резултати показују велики потенцијал смањења потрошње горива применом ЕХПС на бази ултракондензатора. Наиме, вредности од 24% до 37% релативног смањења апсолутне вредности потрошње горива постижу се за различите конфигурације система. Као што је и очекивано, најмања вредност уштеде горива постиже се за ЕХПС са најмањом ЕМ, акумулатором енергије најмањег капацитета и са највећим ограничењем јачине електричне струје од 300 А. Повећањем ЕМ са вредности параметра motsize од 0,4 до 0,6, са последицом повећања максималне снаге електричног мотора са 70 на 105 kW, знатне потрошњи горива ce постижу и износе 6% шест додатне уштеде v за ултракондензаторских модула. Са накнадним повећањем обртног момента мотора, потенцијал смањења потрошње прати закон опадајућих приноса [99], [100], где коначни скок у јачини ЕМ доноси само 1% инкременталног повећања ефикасности.



Утицај капацитета акумулатора енергије (ултракондензаторских модула) је такође знатна, са потенцијалима инкременталног смањења потрошње горива која се крећу од 3% (за ЕМ најмање снаге и без ограничења у јачини електричне струје), до вредности које превазилазе 10% (за ЕМ највеће снаге и ограничење електричне струје од 300 А) за прелазак са 2 на укупно 6 ултракондензаторских модула.





Слика 4.7: Смањење потрошње горива за ЕХПС без ограничења у јачини ел. струје (степен редукције)

Повећањем енергетског капацитета акумулатора расте напон за дати степен напуњености јер се повећава број модула повезаних серијски. То омогућује пропорционално смањење јачине електричне струје за регенеративно кочење дате снаге, чиме се смањује употреба фрикционих кочница и повећава количина прикупљене енергије услед избегавања примењених ограничења у погледу максималне јачине електричне струје кроз систем. Зато је ефекат повећања ограничења максималне јачине електричне струје на смањење потрошње горива минималан за конфигурацију ЕХПС са највећим енергетским капацитетима.

Резултати оптимизације у функцији броја ултракондензаторских модула за различите вредности преносног односа између електричне машине и мењача и за променљиве вредности максимално дозвољене јачине електричне струје система приказани су на сликама 4.5 до 4.7. За поменуте резултате, вредност величине ЕМ била је 1,0.

Варијацијом функционалног параметра *reductor* омогућен је оптималан одабир конструкције ЕХПС у погледу преносног односа између ЕМ и мењача. Уколико је овај преносни однос сувише низак, радне тачке ЕМ за дату вредност брзине кретања возила налазе се у пољу са малим вредностима броја обртаја, ограничавајући доступну снагу. Ако су вредности преносног односа сувише велике, радне тачке ЕМ могу се померити сувише удесно, где степен корисности опада.

Утицај поменутог функционалног параметра ограничен је и осетљивост других параметара на оптималан избор преносног односа практично је непостојећа. Највећа осетљивост приметна је код ограничених вредности капацитета акумулатора енергије. Према приказаним резултатима, може се закључити да је оптималан преносни однос у околини вредности 3,0. Изузетак су конфигурације са 2 ултракондензаторска модула и ограничењем струје од 300 и 500 А, где је оптималан преносни однос 4,0.

### 4.4 Хидраулични хибридни погонски систем

Као и у случају оптимизације функционалних и управљачких параметара ЕХПС базираног на употреби ултракондензатора, извршена је слична процедура за један ХХПС. Формиран је калибрисани модел погонског система који је прилагођен употреби у оквиру оптимизационих прорачуна применом динамичког програмирања. Извршена је дискретизација система једначина стања акумулатора енергије 3.23 и 3.24. Модели погонске машине као и акумулатора приказани су у поглављу 3.4.

Разматран је паралелни систем где је реверзибилна XM, која преузима улогу пумпе у фазама регенеративног кочења возила и мотора у сукцесивним процесима погона, смештена иза преносног механизма са фиксним односом 1,2. Та вредност је изабрана како би се радно поље XM прилагодило опсегу броја обртаја погонског вратила возила.

Оптимизација функционалних параметара хидро-пнеуматског акумулатора извршена је варијацијом неколико променљивих и анализом утицаја на укупну потрошњу горива. Једна од њих је преднапрезање акумулатора. Оно је дефинисано као притисак гаса у потпуно испражњеном хидро-пнеуматском акумулатору, при унапред дефинисаној температури. Преднапрезање акумулатора је, дакле, пропорционално маси гаса у њему. Поред ових, анализирани су утицаји капацитета акумулатора (запремине) и масе еластомерне пене на укупну потрошњу горива. Вредности функционалних променљивих дати су у табели 4.2.

Функционални параметар	Назив	Јединица	Случај 1	Случај 2
Преднапрезање	preload	[bar]	70; 90; 110; 130; 150	70; 90; 110; 130; 150
Капацитет	accu	[dm <sup>3</sup> ]	50	30; 50; 70; 90
Маса пене	mf	[kg]	0; 3; 6	=1,233mg
Маса гаса	mg	[kg]	=f( <i>preload</i> )	=f(preload,accu)
Термална константа	tau	[s]	$=\mathbf{f}(mg)$	=f(mg,accu)

Табела 4.2: функционални параметри ХХПС

Разматрана су укупно два случаја комбинација независно променљивих. У првом случају анализирани су утицаји преднапрезања и масе пене на перформансе акумулатора. Маса гаса у хидро-пнеуматском акумулатору израчунава се на основу запремине акумулатора, притиска преднапрезања, референтне температуре (која износи 320 K) и фактора реалног гаса Z. Референтна вредности термалне константе акумулатора мења се јер зависи од масе азота, која се мења услед различитих притисака преднапрезања.

У случају 2, циљ је био одређивање оптималне вредности капацитета хидро-пнеуматског акумулатора за дате околности, респективне вредности преднапрезања, као и међузависности ова два параметра на укупне перформансе ХХПС. Маса пене држи се пропорционалном маси азота са фиксним односом 1,233 (однос маса пене и гаса коришћених за потврду математичког модела хидро-пнеуматског акумулатора [101]). Поред зависности масе азота у акумулатору од притиска преднапрезања, уведен је и утицај саме запремине у овом случају. Такође, услед зависности термалне константе од капацитета акумулатора преко укупне површине његових зидова, узет је у обзир и тај утицај и израчунати су параметри за све вредности запремине хидро-пнеуматског акумулатора.

Треба напоменути да је за еластомерну пену узета вредност специфичне топлоте од 2300 J/kgK, док је за азот уведен температурно-зависни модел заснован на полиномима НАСА/Годрон-Мекбрајд (Gordon-McBride) [102].

У погледу граничних услова оптимизационих прорачуна, задате су вредности дозвољених температура азота у опсегу од 280 до 400 К, док је максимални дозвољени притисак 350 bar. Максимална вредност специфичне запремине гаса израчуната је уз помоћ једначине Бенедикт-Веб-Рубин, узимајући у обзир максималну вредност запремине акумулатора и референтну вредност температуре. Минимална вредност специфичне запремине гаса постављена је узимајући у обзир максималну дозвољену вредност притиска и минимално дозвољену температуру азота. Температура зида хидропнеуматског акумулатора постављена је на 320 К и не мења се током времена.

На слици 4.8 приказане су апсолутне вредности потрошене количине горива за случај 1. Оне су добијене оптимизацијом управљања и приказане су за различите комбинације функционалних параметара. На слици 4.9 приказане су вредности релативног смањења у потрошеној количини горива у односу на случај КПС. Очигледан је знатан утицај масе еластомерне пене на перформансе хидро-пнеуматског акумулатора. За случај употребе акумулатора без пене, јавља се драстично повећање потрошње горива на нижим вредностима притиска преднапрезања. Додавањем 6 kg пене на притиску преднапрезања од 70 bar добија се инкрементално смањење у потрошњи горива од 6%. Повећање масе еластомерне пене од 3 до 6 kg доноси додатних 0,5% уштеда у потрошњи горива.

На дијаграму 4.10 приказани су токови температуре и притиска гаса у акумулатору енергије за једну секцију разматраног возног циклуса. Приказани су резултати за три различите вредности еластомерне масе. Након једне фазе регенеративног кочења најмањи притисак азота постиже се за акумулатор без еластомерне пене. Анализом тока температуре јасно се може закључити узрок. Наиме, температура азота врло брзо након почетка кочења достиже граничну вредност од 400 К, након чега негативну вучну силу пружају искључиво фрикционе кочнице. Повећањем масе еластомерне пене за дату масу азота у акумулатору, варијације температуре смањују се и гранични услови достижу се касније, уколико се уопште и достигну, тиме дозвољавајући већу регенерацију кинетичке енергије.



Анализирајући резултате оптимизације ХХПС за случај 1, приметан је утицај масе еластомерне пене на оптималну вредност притиска преднапрезања. Наиме, са повећањем масе пене, смањује се оптимална маса притиска преднапрезања. Са повећањем преднапрезања акумулатора достижу се веће средње вредности притиска током циклуса (дијаграм 4.11), што доводи до повећања потенцијалног обртног момента на вратилу хидрауличне машине. Веће вредности притиска преднапрезања доносе и веће масе азота, што за дату вредност укупне површине зидова акумулатора доводи до повећања термалне константе. Са друге стране, за дату количину масе еластомерне пене, смањење вредности притиска преднапрезања узрокује већи однос маса пене/гаса, што смањује варијације температуре и тако потенцијално повећава количину енергије коју је могуће прикупити за дате граничне услове.

Дијаграм 4.12 приказује укупан степен корисности ХХПС за случај 1. Степен корисности је добијен дељењем укупне количине енергије испоручене од стране хидрауличног мотора погонском систему возила и укупне апсорбоване количине енергије од стране хидрауличне пумпе.



Слика 4.10: Ток притиска и температуре гаса у хидро-пнеуматском акумулатору за различите количине еластомерне пене (секција од 280 до 390 s разматраног циклуса, случај 1)



Иако се максималне вредности достижу за најмање притиске преднапрезања акумулатора, оптималне вредности притиска са аспекта потрошње горива достижу се између 110 и 130 bar код акумулатора које садрже еластомерну пену. То је узроковано превасходно већом апсорбованом механичком енергијом на вишим притисцима преднапрезања. Основни разлог тренда смањења степена корисности ХХПС са повећањем притиска преднапрезања јесте пад запреминског степена корисности. Смањене вредности степена корисности ХХПС за случај коришћења хидро-пнеуматског

акумулатора без еластомерне пене узроковано је мањим оптерећењима XM дуж разматраног возног циклуса.

Као што је напоменуто раније, у случају 2 коришћене су две независне, функционалне променљиве: капацитет, тј. запремина и преднапрезање акумулатора. С обзиром да је претпостављена пропорционална зависност укупне површине зидова акумулатора од његове запремине, резултујуће вредности термалне константе за случај 2 зависе искључиво од притиска преднапрезања, са чијим повећањем оне расту.



Дијаграми 4.13 и 4.14 показују да је максимално побољшање економичности горива достигнуто за случај коришћења акумулатора са највећим капацитетом од 90 dm<sup>3</sup>. Највећи потенцијал смањења потрошње горива за акумулатор најмање запремине износи 20,4%. Инкрементална побољшања у економичности горива смањују се након 50 dm<sup>3</sup>. Наиме, повећањем капацитета акумулатора енергије за 20 dm<sup>3</sup> (од 70 до 90 dm<sup>3</sup>), добија се инкрементално побољшање од само 0,7% у уштеди горива за разматрани возни циклус.

Са повећањем запремине хидро-пнеуматског акумулатора, масе азота и еластомерне пене расту, доносећи мање варијације температуре и повећавајући степен корисности. Са друге стране, повећање капацитета акумулатора енергије смањује средње вредности притиска гаса током возног циклуса, смањујући потенцијални обртни момент који је доступан на вратилу XM. Ипак, највеће уштеде у потрошњи горива постигнуте су са највећим акумулаторима јер доносе пропорционално већи потенцијал акумулације енергије. Оптималне вредности притиска преднапрезања расту са повећањем запремине хидропнеуматског акумулатора.



На слици 4.16 приказан је дијаграм зависности укупног степена корисности ХХПС од притиска преднапрезања, за различите вредности капацитета акумулатора енергије. Приметно је да је утицај капацитета акумулатора на овај показатељ занемарљиво мали, са највећим разликама степена корисности ХХПС које достижу 1%. Утицај притиска преднапрезања на укупни степен корисности ХХПС показује тренд који је упоредив са оним приказаним за случај 1, где ефикасност пада са повећањем преднапрезања, услед неповољног утицаја на запремински степен корисности ХМ.

# 5 Извођење алгоритма управљања применом

# неуронских мрежа

У овом поглављу ће бити представљена метода, резултати и закључци у погледу извођења алгоритма управљања из решења добијених применом ДП који су предмет претходног поглавља. У начелу, циљ би се могао формулисати кроз исказ о добијању перформанси ХПС који су блиски оптималним, тј. оним који су добијени применом методе ДП, извођењем једног управљачког алгоритма који ће, поред неопходног услова могућности директне примене на разматраним ХПС, испуњавати и оне о задовољавајућем учинку у свим експлоатационим условима.

Разматрана методологија извођења алгоритма управљања подразумева примену машинског учења над посебно припремљеним и организованим подацима, и то:

- сетом параметара возног циклуса,
- радних параметара погонског система и
- одговарајуће вредности оптималног управљања,

са циљем откривања одређених образаца којим се повезују тренутно и стања система у прошлости са управљачким параметром који доноси највећи учинак.

Најпре ће бити приказани кратки преглед и подела техника, метода и алгоритама машинског учења као области вештачке интелигенције. Затим ће бити представљени тип и конфигурација изабране неуронске мреже за извођење управљачког алгоритма. Биће описани подаци који ће бити употребљени у процесу тренирања мреже. Након појединости који се тичу самог процеса тренирања изабраних конфигурација неуронске мреже, извршиће се валидација исте на основу података који нису били употребљени током фазе учења. На крају, биће приказани упоредни подаци постигнутих перформанси ХПС у погледу уштеда у гориву применом на овај начин добијених алгоритама управљања и референтних (ДП) и биће изведени закључци у вези са приказаном методологијом.

### 5.1 Машинско учење

Машинско учење припада методама и техникама вештачке интелигенције чији је циљ стварање модела, тј. извођења законитости или образаца из разматраних података. Користећи информације које су намењене процесу тренирања, тј. учења, применом алгоритама машинског учења могуће је добити модел који се касније може употребити за предвиђање или доношење одлука. Кључна разлика у односу на конвенционалне, аналитичке методе моделирања лежи у чињеници да се, анализирајући податке у процесу обуке, коначни модел може употребити за задатке које корисник тог алгоритма није првобитно предвидео или испланирао. Сам процес учења, тј. тренирања може се обавити, у општем случају, на три начина:

- Надзирано учење,
- Учење без надзора и
- Оснажено учење.



Слика 5.1: Процес машинског учења [103]

Алгоритми за надзирано учење подразумевају формирање модела на основу улазних података и жељених одзива (излаза, решења, циљева) који се могу састојати од нумеричких вредности или ознака класа. Овај начин учења аналоган је оном кроз који човек пролази у процесу усвајања нових знања. Уколико је циљ решење неког инжењерског проблема, потребно је применити тренутно знање за решење задатка. Постојање тачног одговора омогућава проверу стања знања. Уколико се она не поклапају, потребно је поновити процес уз усвајање нових знања. У овом примеру задатак и решење су део улазних података за тренирање, док знање представља модел. Итеративном оптимизацијом током времена, модел се усавршава и доводи у жељено стање минимизацијом разлике жељеног одзива и излаза модела. Треба напоменути да се овај начин учења може применити на примерима класификације, чији је циљ квалитативна променљива и регресије, чији су излази нумеричке вредности.

Учење без надзора користи само улазне податке (без одговора, циљева, решења) и користи се за проналажење образаца, тј. структуре. Овај тип учења користи се за груписање података кроз детекцију особености у њима и сукцесивним проверама њиховог присуства или одсуства у новим узорцима. Често се користи и као метод препроцесирања података пре примене других начина учења.

Оснажено учење се примењује код проблема где је потребно одредити оптималну интеракцију на задате услове. Користи се код аутономних возила и у теорији игара. Поред улазних података и ограничених жељених одзива, подразумева и оцену предвиђених излаза на основу којих се модел побољшава. Учење на основу награде и казне била би добра аналогија овом начину усвајања знања у машинском учењу.

### 5.2 Неуронске мреже

Неуронска мрежа је најчешће коришћен модел у оквиру машинског учења и састоји се од мноштва вештачких неурона који опонашају биолошке неуроне. Прва практична примена вештачких неуронских мрежа (ВНМ у даљем тексту) дошла је крајем педесетих година прошлог века са перцептроном Френка Розенблата (*Frank Rosenblatt*) [104]. Иако су први резултати показали обећавајуће перформансе у области препознавања образаца, мреже које користе перцептроне и одговарајуће алгоритме тренирања, тј. учења нису се показале успешним у решавању осталих проблема. Због недоступности јаких рачунара и недостатака нових идеја у методама тренирања мрежа, неколико деценија није било пробоја на пољу примене неуронских мрежа. Осамдесетих година прошлог века, проналаском алгоритма повратног ширења (*backpropagation algorithm*) за тренирање вишеслојних мрежа перцептрона [105], [106] и појавом брзих рачунара враћено је интересовање у ову област вештачке интелигенције.



Окосницу неуронских мрежа чини неурон, чији је математички модел је приказан на слици 5.2. Скаларни улаз p множи се тежинским коефицијентом w и резултат wp прослеђује се у сабирач где се додаје вредности офсета b ("bias"). Резултат сабирања, n, тј. нето улаз, прослеђује се преносној функцији f, која производи скаларни излаз a.

а = f(Wp+b) Слика 5.4: Једнослојна мрежа са S неурона и R улаза [56]

Излаз неурона може се израчунати као

$$a = f(wp + b). \tag{5.1}$$

Вредности офсета и тежинског коефицијента су променљиве које се могу подешавати у процесу тренирања.

У пракси, не користе се мреже са једним неуроном, макар били и са више улаза. Пример једне мреже са више неурона и улаза приказан је на слици 5.4. Сваки улаз повезан је са сваким неуроном. Матрица тежинских коефицијената величине је  $S \times R$ , где је S број неурона, а R број улаза. Сваки неурон има своју вредност офсета, сабирач, преносну функцију и излаз тако да излаз мреже чини вектор a.
Сложенији модели захтевају вишеслојне мреже. На слици 5.5 приказана је једна трослојна неуронска мрежа са R улаза. Сваки слој има своју одговарајућу матрицу тежинских коефицијената W, припадајући вектор офсета b, вектор нето улаза n и вектор излаза a. Треба напоменути да сваки слој може имати различити број неурона. Излази првог слоја представљају улазе за други а излази другог слоја су улаз за трећи слој. Слој чије излазне вредности представљају излаз целокупне мреже је излазни слој. Остали слојеви зову се скривени слојеви. У представљеном примеру, слојеви 1 и 2 су скривени, а слој 3 је излазни слој.



Слика 5.5: Тгослојна мрежа са S неурона и R улаза [56]

	Υ .	Ŷ	•		
1абела 5.1:11	реглел лефиниција	преносних функци	іа кол неv	ронских мрежа	1561
1000000 0010 11	p ====== , , , , , , , , , , , , , , , ,		ja no <u>g</u> noj	percenti nipente	. [ ]

Преносна функција	Дефиниција	Симбол
Тврда граница	a=0 $n<0a=1 n\geq 0$	
Симетрична тврда граница	a = -1 $n < 0a = +1 n \ge 0$	Ŧ
Линеарна	a=n	$\neq$
Линеарна са засићењем	$a=0  n<0 \\ a=n  0 \le n \le 1 \\ a=1  n>1$	$\square$
Симетрична линеарна п.ф. са засићењем	a=-1 $n<-1a=n -1\le n\le 1a=1$ $n>1$	$\neq$
Сигмоидна	$a = \frac{1}{1 + e^{-n}}$	ſ
Сигмоидна п.ф. хиперболичног тангенса	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	£
Позитивно линеарна	$\begin{array}{l} a=0  n<0\\ a=n  0 \le n \end{array}$	$\square$

У конструисању неуронских мрежа, велики број независно променљивих могуће је дефинисати на основу дефиниције и карактеристике проблема. Наиме, број улаза одређен је бројем расположивих излазних променљивих. Број потребних излаза неуронске мреже и опсег диктирају број неурона у излазном слоју и респективне преносне функције.

Поред врста неуронских мрежа које су до сада приказане и које садрже само основне елементе попут сабирача, преносних функција и где се сигнал простире напред (од улаза до излаза), и чији излаз не зависи од редоследа улазних вредности, постоје и динамичке и још специфичније, рекурентне мреже код којих, у општем случају, излаз зависи и од претходних вредности улаза, излаза и стања система. Ради се о неуронским мрежама које одликује постојање меморије и које су нарочито корисне за препознавање рукописа, говора, за прогнозирање динамичких појава, итд.



Слика 5.6: Нелинеарна, ауторегресивна мрежа са спољашњим улазом (NARX мрежа) [56]

Једна од таквих мрежа приказана је на слици 5.6. Ради се о такозваној NARX мрежи (Nonlinear Autoregressive neural network with eXternal input – нелинеарна, ауторегресивна неуронска мрежа са спољним улазом), која спада у групу динамичких мрежа са рекурентним везама, тј. са повратном спрегом. Улазни вектор величине R пролази кроз одлагач (функцију кашњења одређене величине), пролази кроз матрицу тежинских коефицијената улаза и бива сабран са офсетима у сабирачу. Са друге стране, излаз неуронске мреже се такође прослеђује у сабирач првог слоја мреже путем одлагача и матрице тежинских коефицијената слоја. У првом слоју користи се сигмоидна преносна функција хиперболичног тангенса, док се у излазном слоју користи линеарна преносна функција. Сваки слој може имати независтан број неурона и он зависи од жељеног задатка, комплексности модела и дефиниције проблема.

# 5.3 Конфигурација неуронске мреже

За потребе извођења, тј. идентификације образаца из резултата оптималног управљања добијених применом методе ДП, употребиће се нелинеарна ауторегресивна неуронска мрежа са спољним улазом у оквиру метода машинског учења.

Користиће се пакет алата доступних у програмском окружењу МАТLAB који обједињују алате за конструисање, тренирање и анализу неуронских мрежа (*Deep Learning Toolbox*) [107].

На слици 5.7 приказан је основни модел једне NARX неуронске мреже са подразумеваним вредностима параметара. Приказан је модел у отвореном стању, где се излаз неуронске мреже не прослеђује на њен улаз стања. Поред улаза које одговара стању неуронске мреже (y(t)), налази се и улаз који прослеђује вредности спољних параметара у мрежу. Иза оба улаза налазе се линије задршке које задржавају тренутну вредност улаза и вредности претходне итерације (укупне величине 2 у подразумеваном случају).



Слика 5.7: Приказ једне NARX неуронске мреже са подразумеваним подешавањима [107]

Након проласка сигнала кроз линије кашњења, улази се у скривени слој неуронске мреже где се вредности улаза множе тежинским коефицијентима и сабирају са вредностима офсета. Укупан број неурона у скривеном слоју (који садржи само један слој у подразумеваном случају) је 10. Код скривеног слоја користи се сигмоидна преносна функција хиперболичног тангенса. Излазни слој ове неуронске мреже, у подразумеваном случају, састоји се од једног неурона и користи се линеарна преносна функција.

Спољни улаз може бити вишедимензионални и на тај начин неуронска мрежа може узети у обзир више променљивих у предвиђању жељеног излазног стања. У оквиру овог истраживања, одлучено је да се користе вредности параметара чија доступност може бити релативно лако обезбеђена уз помоћ неколико мерних ланаца. Коришћене су вредности:

- тренутне брзине кретања возила,
- обртног момента на погонском вратилу као репрезент траженог оптерећења погонског система,
- тренутно специфично оптерећење хидрауличне машине (однос тренутног и максималног капацитета XM),
- и притисак у хидро-пнеуматском акумулатору енергије.

Циљ је да се тренирањем неуронске мреже изведе алгоритам управљања који ће на основу поменутих улазних вредности и претходних вредности управљачког параметра (расподеле оптерећења између примарне и секундарне погонске машине) обезбедити перформансе које су блиске оним постигнутим применом динамичког програмирања. У наставку извршиће се процес тренирања, процене перформанси и оцене неуронске мреже за различите конфигурације величине линија задршки на улазу, броја неурона у скривеном слоју и укупног броја слојева. Коришћене су вредности броја неурона по слоју од 2 до 20 и величине задршки независних улазних вредности и повратне спреге стања мреже од 10 до укупно 60 итерација.

# 5.4 Процес тренирања неуронске мреже

Ради извођења закона управљања и формирања адекватног управљања радом ХПС за све експлоатационе услове који се могу сусрести у раду аутобуса јавног градског превоза, коришћени су возни циклуси који су снимљени у различитим условима саобраћаја и оптерећења аутобуса као скуп података за тренирање неуронске мреже.

За сваки смер саобраћаја аутобуса изабрана су по три возна циклуса, по један из сваке категорије према критеријуму укупног трајања возног циклуса и то тако што је изабран циклус у другој групацији према критеријуму средње брзине кретања возила за одговарајућу категорију трајања циклуса. Дакле, за циклусе 330 001\_07\_1, 290001\_05\_1 и 270001\_04\_1 из групације возних циклуса снимљених у смеру кретања возила 1, и за циклусе 330 001\_02\_2, 270 001\_07\_2 и 360 001\_09\_2 из групације циклуса у смеру кретања 2 су спроведени оптимизациони прорачуни применом ДП за функционалне параметре ХПС приказане у табели 5.2.

Табела 5.2:	Функционални	параметри	ХХПС	коришћени	за	формирање	скупа	података	за
тренирање	неуронске мреж	ce							

Функционални параметар	Назив	Јединица	Вредност
Преднапрезање	preload	[bar]	130
Капацитет	асси	[dm <sup>3</sup> ]	50
Маса пене	mf	[kg]	8,2265
Maca raca	mg	[kg]	6,6703
Термална константа	tau	[s]	503,8

На слици 5.8 приказан је дијаграм укупног времена извршења ДП у функцији трајања разматраног возног циклуса. Прорачун је спроведен на радној станици опремљеној Intel Xeon E5645 процесором. Време извршења оптимизације скоро два пута је дуже од трајања самог возног циклуса. То потврђује високу сложеност проблема оптимизације која се огледа у немогућности примене радне станице за формирање оптималног управљања у реалном времену и у случајевима када би било могуће детерминистички предвидети будућа стања ХПС.

Треба напоменути да је коришћен временски интервал од 0,2 s током процеса оптимизације ради повећања тачности предвиђања оптималне потрошње горива и расподеле оптерећења ХПС. Број дискретних стања ХПС (температуре и специфичне запремине хидро-пнеуматског акумулатора) разматраних током оптимизације износи 41. Вектор расподеле оптерећења ХПС подељен је такође на укупно 41 вредност од 0 до 1.



Слика 5.8: Трајање спровођења оптимизационог прорачуна применом ДП за разматране возне циклусе и конфигурацију ХПС

Резултати оптималне расподеле оптерећења ХПС, са осталим релевантним подацима и параметрима добијеним симулацијом поменутих возних циклуса, пре свих вредностима параметара који се користе као спољни улаз мреже, састављени су и смештени у облик који је погодан за тренирање изабране неуронске мреже. Сви релевантни подаци подељени су у три групе, где 70% улазних вредности чине скуп података за тренирање неуронске мреже, док је осталих 30% подељено у две групе једнаке величине – један скуп користи се за правовремено заустављање процеса учења а други за оцену истрениране неуронске мреже. Наиме, како би се обезбедила довољна генерализација неуронске мреже, односно осигурале повољне перформансе за податке који нису део скупа којим се тренира мрежа, потребно је избећи стање "прекомерне" истренираности (*overfitting*) ранијим заустављањем процеса учења. Критеријум за престанак тренирања је 6 узастопних итерација у којима нема побољшања, односно смањења, средњег квадратног одступања оптималне расподеле оптерећења ХПС.

За тренирање мреже коришћен је алгоритам Левенберг-Марквуард ("Levenberg-Marquardt") са простирањем уназад (*backpropagation*). Вредности тежинских коефицијената и офсета мреже иницијализоване су употребом методе Нгујен-Видроу (*Nguyen-Widrow*) [108].

Најпре ће бити приказана анализа учинка процеса тренирања неуронских мрежа за различита подешавања величине линија задршке улаза стања, спољних параметара и броја неурона у скривеном слоју мреже.

Вредности параметара вештачке неуронске мреже које су биле коришћене приликом процеса тренирања приказане су у табели 5.3.

Варијанта	Задршка	Задршка стања FD	Број неурона LS	Величина
подешавања	спољних	(Feedback Delay)	(Layer Size)	скривеног
неуронске мреже	параметара ID			слоја мреже
	(Input Delay)			
1.	ID=[10, 30]	FD=[10, 30]	LS=[4, 8, 12]	1
2.	ID=[20, 60]	FD=[20, 60]	LS=[4, 10, 20]	1
3.	ID=[10, 20, 30]	FD=3·ID	LS=[2, 6, 10, 14, 18]	1
4.	ID=[10, 20]	FD=3·ID	LS=[4, 8]	2
5.	ID=[10, 20, 30]	FD=ID	LS=[2, 6, 10, 14, 18]	2

Табела 5.3: Приказ и опис коришћених варијанти подешавања вештачких неуронских мрежа

Вредности параметара које су приказане у угластим заградама представљају независне променљиве величине. На пример, у случају варијанте подешавања неуронске мреже број 1, величине линија задршке спољних параметара, као и стања неуронске мреже, али и броја неурона у скривеном слоју мреже су независно променљиве и укупно 12 комбинација параметара је коришћено приликом процеса тренирања ВНМ. За случај под редним бројем 4, независно променљиве величине су величина линије задршке улазних параметара и број неурона у скривеном слоју мреже, док се за вредности величине линије задршке стања мреже узимају вредности које су три пута веће од првопоменутих.

За сваку разматрану конфигурацију неуронске мреже, извршено је укупно десет процеса тренирања у циљу смањења утицаја иницијализације на учинак мреже. Тиме ће бити омогућено исправно расуђивање о ефектима појединих параметара мреже на понашање и праћење жељеног тока расподеле оптерећења ХПС.



Слика 5.9: Кутијасти дијаграм трајања процеса тренирања ВНМ у зависности од укупног броја параметара за тренирање

Коначан број успешно тренираних мрежа зависи од учестаности појава раног прекида процеса тренирања узрокованих прекорачењем вредности параметра који регулише брзину учења вештачке неуронске мреже.

На слици 5.9 приказан је кутијасти дијаграм укупног трајања процеса тренирања ВНМ у функцији броја њихових тежинских коефицијената и офсета. Треба напоменути да је на ординати коришћења логаритамска скала. Укупан број коефицијената који се одређују процесом тренирања добија се сабирањем свих тежинских коефицијената матрица сваког појединачног слоја и броја офсета. Начелно гледано, приметан је тренд раста времена тренирања са повећањем сложености разматране конфигурације ВНМ. Од ВНМ са 865 вредности променљивих параметара па све до најсложеније ВНМ (са укупно 5241 коефицијентом) уочљив је линеаран раст времена тренирања, што одговара експоненцијалном повећању утрошеног времена. Максималне вредности трајања тренирања превазилазе 50000 s за случај најсложенијих ВНМ на радној станици опремљеној Intel Xeon E5645 процесором.

## 5.4.1 Резултати тренирања неуронских мрежа према варијанти 1

У наставку ће бити приказани резултати тренирања вештачке неуронске мреже за вредности независно променљивих величина задршки спољних параметара и стања система од 10 и 30, и за вредности броја неурона у скривеном слоју мреже од 4, 8 и 12. На тај начин биће омогућено утврђивање утицаја појединих параметара неуронске мреже на учинак, односно степен поклапања са оптимално одређеном расподелом оптерећења ХПС.

Задршк	a	Задршка	Број	Средње	Медијана	Стандардно	Средње	Број
спољни	х	стања FD	неурона	квадратно	средњег	одступање	квадратно	важећих
парамет	гара	(Feedback	LS (Layer	одступање	квадратног	[-]	одступање –	мрежа
ID (	Input	Delay)	Size)	[-]	одступања		осредњени	[-]
Delay)					[-]		излаз свих	
							мрежа [-]	
10		10	4	0.03166	0.03112	0.00173	0.03043	10
10		30	4	0.03169	0.03123	0.00141	0.03012	10
30		10	4	0.03238	0.03126	0.00229	0.03000	10
30		30	4	0.03884	0.03200	0.01280	0.03173	10
10		10	8	0.02998	0.02992	0.00049	0.02882	10
10		30	8	0.03040	0.03032	0.00047	0.02917	10
30		10	8	0.03044	0.03035	0.00032	0.02904	10
30		30	8	0.03108	0.03114	0.00038	0.02957	10
10		10	12	0.02949	0.02931	0.00062	0.02820	10
10		30	12	0.03013	0.03002	0.00064	0.02879	9
30		10	12	0.03037	0.03044	0.00044	0.02884	10
30		30	12	0.03105	0.03090	0.00066	0.02918	10

Табела 5.4: Приказ учинка процеса тренирања неуронских мрежа према варијанти 1



Слика 5.10: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 10, задршка стања 10 (варијанта 1)



Слика 5.11: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 10, задршка стања 30 (варијанта 1)



Слика 5.12: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 30, задршка стања 10 (варијанта 1)



Слика 5.13: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 30, задршка стања 30 (варијанта 1)



Слика 5.14: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 10, задршка стања 10 (варијанта 1)



Слика 5.15: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 10, задршка стања 30 (варијанта 1)



Слика 5.16: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 30, задршка стања 10 (варијанта 1)



Слика 5.17: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 30, задршка стања 30 (варијанта 1)



Слика 5.18: Подударање референтног и тока управљања на основу неуронске мреже, 12 неурона, задршка улаза 10, задршка стања 10 (варијанта 1)



Слика 5.19: Подударање референтног и тока управљања на основу неуронске мреже, 12 неурона, задршка улаза 10, задршка стања 30 (варијанта 1)



Слика 5.20: Подударање референтног и тока управљања на основу неуронске мреже, 12 неурона, задршка улаза 30, задршка стања 10 (варијанта 1)



Слика 5.21: Подударање референтног и тока управљања на основу неуронске мреже, 12 неурона, задршка улаза 30, задршка стања 30 (варијанта 1)

Дијаграми приказују расподелу оптерећења за деоницу возног циклуса која није употребљена за тренирање неуронске мреже. Упоредо су приказани оптимални ток (добијен применом методе динамичког програмирања), расподела оптерећења добијена на излазу мреже са најмањим средњим квадратним одступањем и излазни сигнал израчунат као средња вредност излаза појединачних мрежа. Повећањем броја неурона, побољшава се праћење оптималног тока и успостављања максималних вредности расподеле оптерећења.



Слика 5.22: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 1

Приметан је тренд смањења средњег квадратног одступања при повећању броја неурона у скривеном слоју мреже. Наиме, аритметичка средина свих средњих квадратних одступања успешно истренираних мрежа показује најпре тренд повећаног смањења грешке преласком са 4 на 8 неурона и, накнадно, нешто мањег побољшања перформанси повећањем броја неурона са 8 на 12.

Најбоље слагање са оптимално изведеним управљањем добија се за најмање величине задршки које су коришћене у овој варијанти подешавања мреже (10). Повећање величине задршке са 10 на 30 узрокује смањење перформанси неуронске мреже у праћењу тока оптималног управљања, и то нешто блаже погоршање за улазе стања него за улазе спољних параметара. Повећањем вредности оба параметра на 30, перформансе неуронске мреже знатније се смањују, и то нарочито за случај мреже са 4 неурона у скривеном слоју.

Ток медијане средњих квадратних одступања неуронских мрежа показује сличне вредности и исти тренд као и аритметичка средина за све разматране конфигурације са изузетком вредности грешке за случај коришћења неуронске мреже са 4 неурона и величине задршки од 30 узорака. Наиме, израчунавањем медијане, смањује се утицај екстремних вредности средњег квадратног одступања па је и њена вредност за поменуту конфигурацију знатно мања.

Ток стандардног одступања прати тренд аритметичке средине средњих квадратних одступања свих успешно истренираних неуронских мрежа. Вредности су углавном мање од 0,002, са изузетком мреже са 4 неурона и величином задршки од 30, где је стандардно одступање око 0,013.

Осредњавањем излаза свих неуронских мрежа за једну разматрану конфигурацију повећава се учинак у погледу праћења оптималног тока управљања. Наиме, средње квадратно одступање смањује се за око 4,5% за случај примене најповољније конфигурације (12 неурона, величина задршки од 10). Утицај величине задршки на грешку праћења оптималног управљања нешто је другачији у случају осредњавања излаза успешно истренираних мрежа и огледа се у повећању оптималне величине претходних вредности независних и улаза стања система код мреже са најмањим бројем неурона у скривеном слоју. Тако се добија да је најбољи учинак мреже за случај употребе конфигурације са 4 неурона постигнут са величином задршки улазних параметара од 30 и улаза стања од 10 претходних вредности. Нешто слабије перформансе показује мрежа са 30 вредности улаза стања и 10 вредности улазних параметара.

На сликама 5.23 до 5.25 приказани су дијаграми расподеле грешке праћења оптималног тока управљања за осредњене вредности излаза неуронских мрежа са 4, 8 и 12 неурона у скривеном слоју.



Слика 5.23: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 4 неурона (варијанта 1)



Слика 5.24: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 8 неурона (варијанта 1)



Слика 5.25: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 12 неурона (варијанта 1)

Код неуронских мрежа са најмањим бројем неурона, уочљив је положај вршних вредности заступљености у негативном делу распона грешке управљачког параметра. Дакле, највећи број одступања дешава се у случајевима када је осредњени излаз из мрежа већи од референтног тока управљачког параметра добијеног применом ДП. Највеће вредности заступљености грешке добијају се за случајеве са најмањим разматраним величинама задршки, што одговара мрежама са најмањим вредностима средњег квадратног одступања. Повећањем броја неурона, максималне заступљености грешке управљања групишу се у околини нулте вредности и расподелу одликује већа симетрија, нарочито за случај мрежа са најмањим бројем задршки. Код неуронских мрежа са 12 неурона, уочљиво је додатно груписање положаја и повећање максималних вредности расподеле грешке око нулте вредности грешке.

### 5.4.2 Резултати тренирања неуронских мрежа према варијанти 2

У наставку ће бити приказани резултати тренирања вештачке неуронске мреже за вредности независно променљивих величина задршки спољних параметара и стања система од 20 и 60, и за вредности броја неурона у скривеном слоју мреже од 4, 10 и 20. На тај начин биће омогућено утврђивање утицаја повећања сложености мреже у виду повећаних величина задршки спољних параметара и стања мреже, као и броја неурона у скривеном слоју на коначни учинак неуронске мреже.

Задршка	Задршка	Број	Средње	Медијана	Стандардно	Средње	Број
спољних	стања FD	неурона	квадратно	средњег	одступање	квадратно	важећих
параметара	(Feedback	LS (Layer	одступање	квадратног	[-]	одступање –	мрежа
ID (Input	Delay)	Size)	[-]	одступања		осредњени	[-]
Delay)				[-]		излаз свих	
						мрежа [-]	
20	20	4	0.03185	0.03116	0.00148	0.02987	10
20	60	4	0.03175	0.03169	0.00043	0.03090	10
60	20	4	0.03390	0.03308	0.00202	0.03067	10
60	60	4	0.03367	0.03312	0.00146	0.03116	10
20	20	10	0.03052	0.03051	0.00027	0.02929	10
20	60	10	0.03144	0.03125	0.00062	0.02986	8
60	20	10	0.03193	0.03196	0.00020	0.02975	10
60	60	10	0.03285	0.03264	0.00054	0.03070	9
20	20	20	0.03089	0.03093	0.00037	0.02920	9
20	60	20	0.03212	0.03216	0.00024	0.03026	5
60	20	20	0.03354	0.03361	0.00099	0.03066	10

Табела 5.5: Приказ учинка процеса тренирања неуронских мрежа према варијанти 2



Слика 5.26: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 20 (варијанта 2)



Слика 5.27: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 60 (варијанта 2)



Слика 5.28: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 60, задршка стања 20 (варијанта 2)



Слика 5.29: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 60, задршка стања 60 (варијанта 2)



Слика 5.30: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 20, задршка стања 20 (варијанта 2)



Слика 5.31: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 20, задршка стања 60 (варијанта 2)



Слика 5.32: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 60, задршка стања 20 (варијанта 2)



Слика 5.33: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 60, задршка стања 60 (варијанта 2)



Слика 5.34: Подударање референтног и тока управљања на основу неуронске мреже, 20 неурона, задршка улаза 20, задршка стања 20 (варијанта 2)



Слика 5.35: Подударање референтног и тока управљања на основу неуронске мреже, 20 неурона, задршка улаза 20, задршка стања 60 (варијанта 2)



Слика 5.36: Подударање референтног и тока управљања на основу неуронске мреже, 20 неурона, задршка улаза 60, задршка стања 20 (варијанта 2)

Дијаграми који приказују расподелу оптималног и оптерећења добијену употребом неуронских мрежа за деоницу возног циклуса која није употребљена за тренирање неуронске мреже приказани су на сликама 5.26 до 5.36. Повећањем броја неурона са 4 на 10, побољшава се праћење оптималног тока и успостављања максималних вредности расподеле оптерећења, нарочито у случајевима изразито динамичних промена параметра. Са друге стране, повећање броја неурона у скривеном слоју мреже на 20 доводи до стагнације, односно погоршања учинка мрежа услед већег расипања излаза у областима константних вредности расподеле оптерећења. За дати број неурона у скривеном слоју, повећање величине задршке мреже доводи до пораста средњих квадратних одступања изазваних лошијим праћењем константних вредности оптималне расподеле оптерећења.

У поређењу са резултатима приказаним у претходном одељку, а који се тичу варијанте конфигурације неуронских мрежа 1, нарочито оних који су добијени за најмањи број неурона (4), може се закључити да удвостручавање величине задршки има углавном неповољне ефекте. Наиме, једино у случају употребе осредњеног излаза свих успешно истренираних мрежа са 4 неурона се удвостручавањем величине задршки добијају нешто боље вредности учинка мреже. Додатну занимљивост представља чињеница да је побољшање добијено искључиво када су вредности величина задршки улазних параметара и стања мреже једнаке.

На слици 5.37 приказани су статистички подаци учинка мрежа у варијанти конфигурације параметара 2. За комбинацију параметара броја неурона 20 и највећих вредности величине задршки (60 и 60), процес тренирања мреже није успешно започет услед недовољне количине радне меморије радне станице.

Показатељи учинка мреже попут аритметичке средине средњих квадратних одступања свих успешно истренираних мрежа и медијане средњег квадратног одступања имају свој минимум на вредности броја неурона од 10. Такође, уочљиво је да и у овој варијанти подешавања, најбољи учинак мреже добија се за случајеве где је величина задршки најмања (20 и 20 за улазне параметре и стање система, респективно).

Осредњавањем излаза свих мрежа са датом конфигурацијом и поређењем са оптималним током расподеле оптерећења, добијају се нешто другачији резултати. Глобални минимум грешке добија се за случај употребе мреже са највећим бројем неурона у скривеном слоју. Такође, за мање вредности броја неурона, учинак мреже са величином задршке улазних параметара 60 и стања система од 20 бољи је од мреже која користи 20 претходних вредности улазних параметара и 60 за улаз стања система.



Слика 5.37: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 2

Повећање величине задршке са 20 на 60 узрокује смањење перформанси неуронске мреже у праћењу тока оптималног управљања, и то нешто блаже погоршање за улазе стања него за улазе спољних параметара. Једини изузетак је горепоменути случај осредњавања свих излаза мреже.

Ток медијане средњих квадратних одступања неуронских мрежа показује сличне вредности и исти тренд као и аритметичка средина за све разматране конфигурације са изузетком вредности грешке за случај коришћења неуронске мреже са 4 неурона, где перформансе опадају у свим случајевима повећања величине задршки. Разлог томе јесте смањење утицаја екстремних вредности средњег квадратног одступања мреже на учинак исте. Највеће вредности стандардног одступања постижу се на позицијама на којима постоји неслагање у поретку између параметара средњег квадратног одступања и медијане. То су мреже са 4 неурона и свим комбинацијама величина задршки осим оне са улазним низом од 20 и улазом стања од 60 вредности.

Осредњавањем излаза свих неуронских мрежа за једну разматрану конфигурацију повећава се учинак у погледу праћења оптималног тока управљања. Наиме, средње квадратно одступање смањује се за око 4,2% за случај поређења најповољнијих конфигурација.

На сликама 5.38 до 5.40 приказани су дијаграми расподеле грешке праћења оптималног тока управљања за осредњене вредности излаза неуронских мрежа са 4, 10 и 20 неурона у скривеном слоју.



Слика 5.38: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 4 неурона (варијанта 2)



Слика 5.39: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 10 неурона (варијанта 2)

Код неуронских мрежа са најмањим бројем неурона, уочљив је положај вршних вредности заступљености у негативном делу распона грешке управљачког параметра. Дакле, највећи број одступања дешава се у случајевима када је осредњени излаз из мрежа већи од референтног тока управљачког параметра добијеног применом ДП. Позиционо, максимална вредност заступљености одступања мреже са најбољим учинком најближа је нултој вредности грешке. Са друге стране, поредак максималних вредности заступљености не одговара оном добијеним поређењем аритметичке средине осредњених излаза свих мрежа са истом конфигурацијом јер се највећа вредност добија за случај употребе величине задршки улаза стања од 60 и од 20 за улазне параметре. Поред максималних вредности тока заступљености, на учинак мреже пресудан утицај има сам положај максималне заступљености, који треба да буде што ближи нултој вредности.



Слика 5.40: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 20 неурона (варијанта 2)

Највеће вредности заступљености грешке добијају се за случајеве са најмањим разматраним величинама задршки, што одговара мрежама са најмањим вредностима средњег квадратног одступања. Повећањем броја неурона, максималне заступљености грешке управљања групишу се у околини нулте вредности и расподелу одликује већа симетрија, нарочито за случај мрежа са најмањим бројем задршки. Код неуронских мрежа са 12 неурона, уочљиво је додатно груписање положаја и повећање максималних вредности расподеле грешке око нулте вредности грешке.

Код мрежа са 10 неурона, приметно је значајно померање позиција максимума заступљености грешке на десно. Најближи нултој вредности грешке је врх заступљености мреже која користи већу вредност величине задршке улаза стања, иако је по средњем квадратном одступању осредњених излаза мреже тек на трећем месту. Иако се максимум тока мреже са већом задршком за улазне параметре (60) налази даље од нулте вредности у поређењу са оном која користи већу задршку за улаз стања мреже, она има нешто бољи учинак мреже који се огледа у нижој вредности средњег квадратног одступања.

У случају заступљености грешке за мреже са највећим бројем неурона у скривеном слоју (20), знатно веће максималне вредности добијају се за случај употребе најмањих величина задршки. Иако је максимум тока мреже са већом задршком за улазне параметре нешто већи и ближи нултој вредности од оне која користи већи број претходних вредности за улаз стања мреже, значајно веће вредности у зони позитивних вредности грешке до 0,04 чине је мање успешном у коначном учинку.

## 5.4.3 Резултати тренирања неуронских мрежа према варијанти 3

У наставку ће бити приказани резултати тренирања вештачке неуронске мреже за вредности величина задршки добијене статистичком анализом корелације оптималне расподеле оптерећења и појединачних параметара спољних улаза мреже.



Слика 5.41: Аутокорелација оптималне расподеле оптерећења хибридног погонског система

На слици 5.41 приказан je резултат аутокорелације расподеле оптималне оптерећења добијене спровоћењем алгоритма ДП над подацима који cv коришћени касније за тренирање неуронске мреже. Закључује се да су за вредности величине помака изнад опсега од 60 до 70 (које одговарају временским интервалима од 6 до 7 секунди, респективно) добијене ниске вредности коефицијента корелације које не оправдавају употребу већих вредности величина задршки неуронске мреже.

На дијаграму корелације брзине кретања возила и оптималне расподеле оптерећења

(слика 5.42), највеће вредности постижу се за помаке од 20. Интересантно је приметити да се корелациони коефицијенти за помаке изнад 100 и даље налазе изван граница статистички значајне корелације. Корелације осталих улазних параметара неуронске мреже са оптималном расподелом оптерећења ХПС показују нешто другачији тренд. Наиме, за сва три остала параметра (укупно оптерећење ПС, нормализовано оптерећење ХМ и притисак гаса у хидро-пнеуматском акумулатору), за мале вредности помака добија се негативна корелација, да би се затим ушло у поље у којем фигуришу вредности које не показују статистички значајне корелације и на крају добиле и позитивне вредности корелације за првих 20 вредности помака, док је за случај притиска у акумулатору значајно првих 40 вредности.



Слика 5.42: Корелација брзине кретања возила и оптималне расподеле оптерећења



Слика 5.43: Корелација укупног оптерећења хибридног погонског система и оптималне расподеле оптерећења

На основу добијених вредности коефицијената корелације, закључује се да је за случај линије задршке стања система потребно узети у обзир 60 претходних вредности расподеле оптерећења ХПС како би се уважиле све значајне вредности аутокорелације (са

коефицијентом изнад 0,05). Имајући у виду да вредности корелације укупног оптерећења ХПС и ХМ залазе у поље статистички незначајне корелације након 20 помака, испитаће се учинак неуронских мрежа са параметрима задршке улазних параметара са управо тим вредностима.



Слика 5.44: Корелација нормализованог оптерећења хидрауличне машине и оптималне расподеле оптерећења

Слика 5.45: Корелација притиска азота у хидро-пнеуматском акумулатору и оптималне расподеле оптерећења

100

У наставку следе резултати тренирања и учинка неуронских мрежа за величине задршке спољних параметара од 10, 20 и 30 претходних вредности и за стање система (расподеле оптерећења) које су три пута веће од првопоменутих (30, 60 и 90 вредности). Користиће се вредности броја неурона у скривеном слоју мреже од 2, 6, 10, 14 и 18. На тај начин биће омогућено и прецизније утврђивање утицаја повећања сложености мреже у виду броја неурона у скривеном слоју на коначни учинак неуронске мреже.

-	•	-		• •		-	
Задршка	Задршка	Број	Средње	Медијана	Стандардно	Средње	Број
спољних	стања FD	неурона	квадратно	средњег	одступање	квадратно	важећих
параметара	(Feedback	LS (Layer	одступање	квадратног	[-]	одступање –	мрежа
ID (Input	Delay)	Size)	[-]	одступања		осредњени	[-]
Delay)				[-]		излаз свих	
						мрежа [-]	
10	30	2	0.04383	0.03819	0.01191	0.03509	10
10	30	6	0.03069	0.03076	0.00046	0.02966	10
10	30	10	0.03016	0.03009	0.00043	0.02896	7
10	30	14	0.03024	0.03015	0.00092	0.02911	4
10	30	18	0.03051	0.03055	0.00025	0.02924	4
20	60	2	0.05008	0.04768	0.01369	0.03833	10
20	60	6	0.03142	0.03134	0.00027	0.02993	10
20	60	10	0.03222	0.03164	0.00198	0.02991	8
20	60	14	0.03152	0.03143	0.00059	0.02951	8
20	60	18	0.03163	0.03166	0.00032	0.02998	5
30	90	2	0.05418	0.05356	0.01444	0.04228	10
30	90	6	0.03232	0.03220	0.00057	0.03095	10
30	90	10	0.03248	0.03227	0.00084	0.03065	9

Табела 5.6: Приказ учинка процеса тренирања неуронских мрежа према варијанти 3



Слика 5.46: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)



Слика 5.47: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)



Слика 5.48: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)



Слика 5.49: Подударање референтног и тока управљања на основу неуронске мреже, 14 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)



Слика 5.50: Подударање референтног и тока управљања на основу неуронске мреже, 18 неурона, задршка улаза 10, задршка стања 30 (варијанта 3)



Слика 5.51: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)



Слика 5.52: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)



Слика 5.53: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)



Слика 5.54: Подударање референтног и тока управљања на основу неуронске мреже, 14 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)



Слика 5.55: Подударање референтног и тока управљања на основу неуронске мреже, 18 неурона, задршка улаза 20, задршка стања 60 (варијанта 3)



Слика 5.56: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 30, задршка стања 90 (варијанта 3)



Слика 5.57: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 30, задршка стања 90 (варијанта 3)



Слика 5.58: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 30, задршка стања 90 (варијанта 3)

На дијаграмима 5.46 до 5.50 приказани су резултати за мреже чије су величине задршки спољних параметара и стања најмање (10 и 30 претходних вредности, респективно). Осим за случај примене неуронске мреже са само 2 неурона у скривеном слоју, резултати праћења оптималне расподеле оптерећења су задовољавајући.

Тренирањем мреже са 2 неурона, долази до формирања модела управљања чији је распон учинка знатан, што доводи до ефекта повећања средњег квадратног одступања обједињавањем и осредњавањем излаза свих успешно истренираних мрежа у поређењу са појединачно најбољом.

Најбољи резултати у погледу праћења оптималног сигнала у овој варијанти добијају се за најмање вредности величина задршки (10/30) и за 14 неурона у случају употребе излаза једне истрениране мреже и 10 неурона када се излази свих успешно истренираних мрежа комбинују. Повећањем броја неурона преко 10, долази до нешто већих расипања излазног параметра при константним вредностима максималне расподеле оптерећења добијене применом ДП.

Токови у средњем квадратном одступању, медијани и средњем квадратом одступању осредњених излаза мреже за све конфигурације разматране у овој варијанти показују исте трендове. Најпре долази до великог пада грешке преласком са 2 на 6 неурона у скривеном слоју мреже, након чега долази до њеног блажег пада и постизања оптимума у области између 10 и 14 неурона и, коначно, до благог пораста грешке при коришћењу 18 неурона. За све разматране вредности броја неурона, мреже са задршком спољних параметара и стања система од 20/60 показују нешто слабије перформансе у односу на мреже са најмањом задршком. Закључује се да се оптимум учинка трениране мреже постиже са мањим бројем претходних вредности узетих у разматрање у односу на оне величине које су корелационом анализом одређене као статистички значајне.

На основу приказаних резултата, закључује се и да смањење учинка мреже проузрокованог недовољно сложеном конфигурацијом (са само 2 неурона у скривеном слоју) не може се компензовати повећањем величине задршки јер и у том случају оно доноси погоршање грешке праћења оптималне расподеле оптерећења.

Осредњавањем свих излаза истренираних мрежа могуће је смањити грешку праћења оптималног сигнала за до 20% у односу на медијану средњег квадратног одступања. Највећи напредак постиже се при коришћењу мреже са 2 неурона и употребом највећих

задршки у овој варијанти (30/90 претходних вредности). За случај употребе најбољих конфигурација (10 и 14 неурона, задршке 10/30), побољшање је нешто испод 4%.



Слика 5.59: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 3

Занимљиво је анализирати перформансе тренирања ВНМ са 10 неурона и средњим величинама задршки (20/60) јер је иста конфигурација коришћена и у варијанти 2 ове анализе. Разлика у средњем квадратном одступању управљања формираног на основу аритметичке средине излаза свих мрежа је мања од 0,13%, што повећава поверење у спроведене анализе утицаја конфигурације неуронских мрежа на сам процес тренирања.

На дијаграмима 5.60 до 5.64 приказане су расподеле грешака праћења оптималног тока управљања добијене за осредњени излаз свих успешно истренираних неуронских мрежа. Подаци који су коришћени за формирање дијаграма расподеле грешке не припадају скупу репрезентативних возних циклуса који су коришћени за сам процес тренирања вештачких неуронских мрежа.

Код мрежа са бројем неурона од 2 и 6, максималне вредности тока расподеле грешке добијају се за вредности величине задршки од 20/60 (за улазне параметре и улаз стања система, респективно). Такође, то је једини ток који има само један локални минимум у распону грешке од -0,1 до 0, али сама позиција вршне вредности заступљености грешке узрокује мањи учинак у односу на конфигурацију са најмањом величином задршки. Повећањем броја неурона са 2 на 6, долази до груписања позиција максималних вредности заступљености грешке око вредности 0, што је и логично, имајући у виду значајно смањење средњег квадратног одступања.



Слика 5.60: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 2 неурона (варијанта 3)



Слика 5.61: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 6 неурона (варијанта 3)



Слика 5.62: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 10 неурона (варијанта 3)



Слика 5.63: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 14 неурона (варијанта 3)

Дијаграм расподеле грешке за случај употребе 10 неурона приказује повећање максималне вредности тока заступљености грешке за конфигурацију са најмањим величинама задршки које је у сагласности са смањењем средњег квадратног одступања комбинованог излаза свих истренираних мрежа. За средњу величину задршки (20/60), добија се смањење максималне заступљености у околини нулте грешке уз задржавање приближно истих вредности средњег квадратног одступања осредњених излаза мреже.

За неуронску мрежу са 14 неурона и најмањим величинама задршки (10/30), вршна вредност заступљености грешке налази се у пољу позитивних, грешака и у односу на мрежу са задршкама од 20/60 претходних вредности нешто је већа.



Слика 5.64: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 18 неурона (варијанта 3)

За 18 неурона у скривеном слоју мреже добијају се нешто ниже вредности максималне заступљености грешке, са додатним одступањем позиција максимума у односу на нулту грешку. Ове чињенице у сагласности су са инкременталним погоршањем учинка (у виду средњег квадратног одступања) у поређењу са конфигурацијама мрежа са 14 неурона.

### 5.4.4 Резултати тренирања неуронских мрежа према варијанти 4

У наставку ће бити приказани резултати тренирања ВНМ за вредности независно променљивих величина задршки спољних параметара од 10 и 20, док ће се за величине задршки стања система узимати вредности које су три пута веће од првопоменутих. Користиће се вредности броја неурона у скривеном слоју мреже од 4 и 8. У овој варијанти се по први пут користи величина скривеног слоја мреже од 2. На тај начин биће омогућено прецизније утврђивање утицаја повећања сложености мреже у погледу броја слојева на укупни учинак неуронске мреже.

Задри	ика	Задршка	Број	Средње	Медијана	Стандардно	Средње	Број
спољи	них	стања FD	неурона	квадратно	средњег	одступање	квадратно	важећих
парам	иетара	(Feedback	LS (Layer	одступање	квадратног	[-]	одступање –	мрежа
ID	(Input	Delay)	Size)	[-]	одступања		осредњени	[-]
Delay	)				[-]		излаз свих	
							мрежа [-]	
10		30	4	0.02952	0.02937	0.00058	0.02793	9
10		30	8	0.02904	0.02919	0.00059	0.02724	10
20		60	4	0.03099	0.03074	0.00069	0.02885	8
20		60	8	0.03007	0.03015	0.00067	0.02809	7

Табела 5.7: Приказ учинка процеса тренирања неуронских мрежа према варијанти 4

За сваку разматрану конфигурацију неуронске мреже, покушано је укупно 10 процеса тренирања.

Резултати приказани на дијаграмима који следе приказују расподелу оптерећења за деоницу возног циклуса која није употребљена за тренирање неуронске мреже. Упоредо су приказани оптимални ток, расподела оптерећења добијена на излазу мреже са најмањим средњим квадратним одступањем и излазни сигнал израчунат као средња вредности излаза појединачних мрежа.



Слика 5.65: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 10, задршка стања 30 (варијанта 4)



Слика 5.66: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 10, задршка стања 30 (варијанта 4)



Слика 5.67: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 60 (варијанта 4)



Слика 5.68: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 20, задршка стања 60 (варијанта 4)

Дијаграми 5.65 и 5.66 приказују резултате за мреже чије су величине улазне и задршке стања најмање (10 и 30, респективно). Може се закључити да је поклапање и праћење оптималног сигнала задовољавајуће чак и за најмање комплексне мреже.

Вештачка неуронска мрежа са најмањим средњим квадратним одступањем релативно добро прати оптимални ток, иако су приметна прекорачења управљачког параметра или умањене амплитуде сигнала у регионима са изразито динамичким променама. Комбиновањем излаза 9 успешно истренираних неуронских мрежа најмање сложености, резултујуће средње квадратно одступање смањује се за 3,6%, са значајно бољим праћењем оптималног параметра расподеле оптерећења. Прекорачења су умањена, а на деоницама са константним вредностима, осцилације параметра су смањене.

Са повећањем броја неурона у скривеним слојевима мреже са 4 на 8, мрежа са најмањим средњим квадратним одступањем има за 3.9% мању грешку у праћењу оптималног параметра. Иако су прекорачења приметна, овог пута и у различитим тренуцима, праћење оптималног параметра на екстремним вредностима је побољшано. Комбиновањем излаза 10 успешно истренираних неуронских мрежа, грешка се смањује за 2,2% у поређењу са појединачном мрежом са најбољим учинком и за 2,5% у поређењу са одговарајућим параметром неуронске мреже са 4 неурона у слојевима мреже.

Удвостручењем величина задршки улазних величина и стања система, учинак неуронске мреже опада, са погоршањем средњег квадратног одступања за 9% у односу на најбољу конфигурацију (величина задршки 10/30, број неурона 8) и од 4,8% у односу на одговарајућу мрежу са 4 неурона. Комбиновањем излаза свих 8 успешно истренираних мрежа, средње квадратно одступање опада за око 5%. Удвостручењем броја неурона у

скривеном слоју мреже постиже се маргинално побољшање од 2,6% у средњем квадратном одступању за случај комбиновања излаза свих истренираних неуронских мрежа.



Слика 5.69: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 4

На дијаграмима 5.70 и 5.71 приказане су расподеле грешака праћења оптималног тока управљања добијене за осредњени излаз свих успешно истренираних неуронских мрежа.

Код мрежа са 4 неурона, позиције максималних вредности тока расподеле грешке добијају се у области негативних грешака управљања, са нешто већим вредностима заступљености за случај коришћења најмањих величина задршки (од 10/30, за улазне параметре и стање система, респективно). И у овом случају, конфигурација мреже са мањим средњим квадратним одступањем осредњених излаза показује нешто веће вредности максимума заступљености грешке и позицију максимума која је ближа нултој грешци.



Слика 5.70: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 4 неурона (варијанта 4)



Слика 5.71: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 8 неурона (варијанта 4)

За случај употребе 8 неурона у скривеном слоју разматраних мрежа, добијају се нешто бољи резултати. Наиме, обе мреже (са задршкама од 10/30 и 20/60) показују значајно веће вредности максимума заступљености грешке као и груписање позиција истих у околини нулте грешке. За разлику од случаја са 4 неурона, у приказаном опсегу грешака нестају локални максимуми заступљености (у околини вредности –0,02 и +0,02) и јавља се само један значајан максимум, онај у околини нулте вредности. Нешто боље постигнуте перформансе у погледу смањења средњег квадратног одступања осредњеног излаза мреже са мањим величинама задршки огледају се и у постизању већих максималних вредности заступљености грешке у односу на мрежу са већим задршкама.

### 5.4.5 Резултати тренирања неуронских мрежа према варијанти 5

У наставку ће бити приказани резултати тренирања ВНМ за вредности величина задршки спољних параметара и стања система од 10, 20 и 30. Користиће се вредности броја неурона у скривеном слоју мреже од 2, 4, 6, 8 и 10. И у овом случају ће се користити двослојни скривени слој мреже. На тај начин биће омогућено прецизније утврђивање утицаја повећања сложености мреже у виду броја неурона и величине задршки на коначни учинак неуронске мреже са двослојним скривеним слојем.

Задршка	Задршка	Број	Средње	Медијана	Стандардно	Средње	Број
спољних	стања FD	неурона	квадратно	средњег	одступање	квадратно	важећих
параметара	(Feedback	LS (Layer	одступање	квадратног	[-]	одступање –	мрежа
ID (Input	Delay)	Size)	[-]	одступања		осредњени	[-]
Delay)				[-]		излаз свих	
						мрежа [-]	
10	10	2	0.03948	0.03394	0.00843	0.03276	10
10	10	4	0.02947	0.02935	0.00093	0.02759	10
10	10	6	0.02862	0.02821	0.00105	0.02690	10
10	10	8	0.04032	0.02787	0.03959	0.02742	10
10	10	10	0.02799	0.02805	0.00053	0.02615	10
20	20	2	0.03956	0.03452	0.00831	0.03304	10
20	20	4	0.02992	0.03000	0.00048	0.02816	10
20	20	6	0.02908	0.02915	0.00057	0.02737	10
20	20	8	0.02955	0.02946	0.00049	0.02728	10
20	20	10	0.02930	0.02917	0.00069	0.02735	10
30	30	2	0.04011	0.03504	0.00849	0.03286	10
30	30	4	0.03258	0.03074	0.00663	0.02876	10
30	30	6	0.02995	0.02989	0.00049	0.02813	10
30	30	8	0.02983	0.02970	0.00069	0.02801	10
30	30	10	0.03032	0.03040	0.00034	0.02809	10

Табела 5.8: Приказ учинка процеса тренирања неуронских мрежа према варијанти 5

Као и у претходним случајевима, за сваку разматрану конфигурацију неуронске мреже, покушано је укупно 10 итерација процеса тренирања са циљем смањења утицаја иницијализације коефицијената и офсета мреже на њен коначни учинак.

Резултати приказани на дијаграмима 5.72 до 5.86 приказују расподелу оптерећења за деоницу возног циклуса која није употребљена за тренирање неуронске мреже. Упоредо су приказани оптимални ток (добијен применом методе ДП), расподела оптерећења добијена на излазу мреже са најмањим средњим квадратним одступањем и излазни сигнал израчунат као средња вредности излаза појединачних мрежа.



Слика 5.72: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)



Слика 5.73: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)



Слика 5.74: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)



Слика 5.75: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)



Слика 5.76: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 10, задршка стања 10 (варијанта 5)



Слика 5.77: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)



Слика 5.78: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)



Слика 5.79: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)



Слика 5.80: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)


Слика 5.81: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 20, задршка стања 20 (варијанта 5)



Слика 5.82: Подударање референтног и тока управљања на основу неуронске мреже, 2 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)



Слика 5.83: Подударање референтног и тока управљања на основу неуронске мреже, 4 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)



Слика 5.84: Подударање референтног и тока управљања на основу неуронске мреже, 6 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)



Слика 5.85: Подударање референтног и тока управљања на основу неуронске мреже, 8 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)



Слика 5.86: Подударање референтног и тока управљања на основу неуронске мреже, 10 неурона, задршка улаза 30, задршка стања 30 (варијанта 5)

Дијаграми 5.72 до 5.76 приказују резултате за мреже чије су величине улазне и задршке стања најмање (10 и 10, респективно) и за различите вредности броја неурона у двоструком скривеном слоју. Осим за конфигурацију мреже са само 2 неурона, може се закључити да је поклапање и праћење оптималног сигнала задовољавајуће чак и за мреже које користе најмањи број претходних вредности улазних параметара и стања. За случај употребе најједноставније конфигурације мреже у варијанти 5, проблем се огледа у недостизању максималних вредности расподеле оптерећења од 1. Нарочито је проблем наглашен уколико се управљање формира на основу осредњеног излаза свих 10 успешно истренираних мрежа. Аритметичка средина свих вредности средњег квадратног одступања конфигурације са 2 неурона је скоро 0,0395. Комбиновањем свих излаза у један управљачки сигнал, средње квадратно одступање смањује се за 17% и достиже вредност од 0,03276 што је доста ближе вредности медијане средњих квадратних одступања. Повећањем броја неурона са 2 на 4 у двоструком скривеном слоју мреже добија се доста боље праћење оптималног тока расподеле оптерећења и долази до значајног пада свих показатеља грешке. Са накнадним порастом броја неурона, долази до све мањег маргиналног побољшања у учинку мреже, до конфигурације са 10 неурона коју одликују најбољи показатељи.

Узимањем већег броја претходних вредности улазних параметара и стања излаза мреже не доноси побољшања нити у једном од разматраних показатеља учинка. Средња квадратна одступања осредњеног излаза мрежа са величином задршки од 20 расте од 0,9% за случај коришћења 2 неурона, до 4,6% за случај мреже са 10 неурона у двоструком скривеном слоју мреже. Што се тиче неуронских мрежа које користе 30 претходних вредности, учинак мреже се погоршава за 0,3% (2 неурона) до 7,4% (10 неурона) у односу на мреже са најмањим величинама задршки. Поређењем медијана средњих квадратних одступања мрежа које користе 10, 20 и 30 претходних вредности, поредак учинка је еквивалентан, са нешто већим релативним вредностима погоршања истог.



Слика 5.87: Статистички параметри учинка разматраних конфигурација неуронских мрежа према варијанти 5

Поједине конфигурације - мреже са 4 и 8 неурона и са величинама задршки од 10/10 и 30/30 упоредиве су са случајевима у варијанти 1 ове студије. Поређењем еквивалентних случајева могуће је квантификовати утицај додатног скривеног слоја код варијанте 5 на укупан учинак мреже. Учинак алгоритма управљања који користи осредњени излаз свих истренираних мрежа побољшан је за око 9% у случају коришћења мрежа са задршкама од 10/10 и бројем неурона од 4 и 8, и у случају коришћења већих задршки од 30/30 и бројем неурона од 4. За конфигурацију мреже са 8 неурона и задршкама од 30/30, смањење средњег квадратног одступања у односу на оптимални ток управљања је 5,3%.

На дијаграмима расподеле грешке праћења оптималног тока управљања уочљив је очекивани тренд повећања максималних вредности и груписања њихових позиција у околини нулте грешке. За случај употребе само 2 неурона у двоструком скривеном слоју мреже, глобални максимум заступљености грешке налази се у области негативних грешака праћења, док се по још један локални максимум уочава са обе стране нулте вредности грешке. Повећањем броја неурона на 4, долази до значајног побољшања расподеле грешке који се огледа у достизању значајно већих максималних вредности у околини нулте грешке и смањења вредности локалних максимума. Уочљиви тренд побољшања наставља се и при додатном повећању броја неурона, све до вредности од 8, када се позиције и вредности максималних заступљености грешке у околини нулте вредности групишу за све вредности величине задршки у варијанти 5.



Слика 5.88: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 2 неурона (варијанта 5)



Слика 5.89: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 4 неурона (варијанта 5)

На дијаграму расподеле грешке праћења оптималног тока управљања хибридним погонским системом за неуронске мреже са 10 неурона у двоструком скривеном слоју уочљиво је погоршање показатеља учинка на распону грешке од -0,1 до 0,1. Наиме, за случај мрежа са задршкама од 20/20 и 30/30 претходних вредности, добија се значајно смањење максималних вредности заступљености, са благим отклоном вршних позиција улево. За обе конфигурације је карактеристично веома благо погоршање учинка у погледу вредности средњег квадратног одступања за осредњени излаз свих успешно истренираних мрежа. Што се тиче мреже са величином задршки претходних вредности од 10/10, такође се добија благо погоршање уочљиве заступљености грешке у управљању у приказаном распону грешке, иако је управо то конфигурација са најбољим учинком

мреже у погледу средњег квадратног одступања. Оно се може објаснити мањим вредностима заступљености грешке у регионима са великим одступањем, који значајније утичу на средње квадратно одступање.



Слика 5.90: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 6 неурона (варијанта 5)



Слика 5.91: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 8 неурона (варијанта 5)



Слика 5.92: Расподела грешке праћења оптималног тока управљања за случај неуронске мреже са 10 неурона (варијанта 5)

# 6 Оцена управљачког алгоритма заснованог на примени вештачких неуронских мрежа

У овом поглављу биће описани методологија и резултати учинка алгоритма заснованог на примени ВНМ на управљање ХХПС. Најпре ће се извршити избор карактеристичних возних циклуса за различите услове саобраћаја. Ти циклуси ће бити касније употребљени у оквиру симулације изабраног ХПС ради валидације управљачког алгоритма базираног на ВНМ и одређивање учинка истог на смањење укупне количине потрошеног горива. Упоредо са тим, формираће се симулациони модели са изабраним возним циклусима који ће бити искоришћени за спровођење оптимизационог прорачуна управљања применом ДП. На тај начин, биће омогућено поређење тако изведеног алгоритма управљања са потрошњом горива добијеном применом референтне, за управљање у реалном времену неупотребљиве, методе.

### 6.1 Избор возних циклуса и конфигурација вештачких

#### неуронских мрежа за валидацију управљања

Слично као и у претходном поглављу, када је било потребно спровести процедуру машинског учења разматраних ВНМ у широком спектру услова, густине и оптерећења саобраћаја, и у оцени учинка тако формираних примењивих управљачких алгоритама потребно је размотрити све категорије експлоатационих услова. Додатно, прорачун и поређење са резултатима добијеним употребом референтне оптимизационе методе биће примењивани на возним циклусима који нису ни у каквом својству разматрани у процесу машинског учења поменутих мрежа.

Размотриће се возни циклуси у оба смера кретања, за по укупно три карактеристична оптерећења у саобраћају. Наиме, од укупног броја снимљених циклуса, насумичним избором ће се одредити 3 репрезентативна за сваки смер кретања. Разматрани критеријум оптерећења у овом случају искључиво је укупно трајање кретања возила од почетне то терминалне станице. У смеру 1, изабрани су циклуси 290 001\_03\_1, 330 001\_03\_1, 350 001\_11\_1, док су за смер 2 изабрани 270 001\_03\_2, 350 001\_14\_2 и 360001\_11\_2.

За смер 1 и разматране возне циклусе за карактеристична стања у саобраћају, највећа потрошња горива добија се у случају средњег оптерећења саобраћаја. За тај циклус добијене су и највеће средње вредности позитивног убрзања и успорења возила, јасно показујући да се ради о возном циклусу са изразито динамичким карактеристикама. Са повећањем средње брзине кретања возила и смањењем укупног трајања циклуса преласком на ниско оптерећење саобраћаја, расте економичност мотора и долази до смањења укупне потрошене количине горива. Преласком на високо оптерећење саобраћаја, долази до повећања укупног трајања возног циклуса и времена стајања аутобуса. Упркос нешто већим вредностима средње масе и нижим вредностима средње позитивне брзине кретања возила, долази до благог пада у потрошеној количини горива у односу на репрезентативни циклус средњег оптерећења.

смер		1		2					
оптерећење [-]	ниско	средње	високо	ниско	средње	високо			
шифра циклуса	330001_03_1	290 001_03_1	350001_11_1	270 001_03_2	350 001_14_2	360 001_11_2			
датум	11.5.2014.	9.5.2014.	12.5.2014.	8.5.2014.	12.5.2014.	13.5.2014.			
почетак циклуса	16:34:34	9:19:24	16:49:06	8:24:24	19:39:19	15:50:25			
крај циклуса	17:13:18	10:03:06	17:37:52	9:07:11	20:24:40	16:48:10			
трајање циклуса [s]	2327	2622	2927	2566	2721	3464			
$v_{\text{pos}}\left[m/s\right]$	6.999	6.384	5.859	6.335	6.081	5.290			
$a_{\text{pos}}\left[m/s^2\right]$	0.442	0.467	0.449	0.499	0.436	0.423			
$a_{neg} \left[m/s^2\right]$	-0.496	-0.506	-0.465	-0.505	-0.464	-0.416			
$m_v \left[ t  ight]$	16.5	17.0	17.5	17.6	19.6	21.3			
m <sub>f</sub> [kg]	6.013	6.851	6.667	5.923	5.273	6.047			
време стајања [s]	497.2	623.4	739.8	532.2	600.8	1009			
удео стајања [%]	21.4	23.8	25.3	20.7	22.1	29.1			

Табела 6.1: Карактеристике возних циклуса изабраних за утвртивање учинка ВНМ

За смер 2, највећа потрошња горива забележена је за репрезентативни возни циклус са високим оптерећењем. У оквиру дате групе која представља једно од три стања оптерећења у саобраћају, најзначајнија корелација са скупом вредности укупне потрошње горива добија се са параметром средњег позитивног убрзања током кретања аутобуса. Због тога се могу десити велика расипања параметра потрошене количине горива у оквиру датог оптерећења. Тако је у смеру 2 добијено да је најмање горива потрошено за репрезентативни возни циклус са средњим оптерећењем у саобраћају. Иако су средње вредности масе значајно веће него у смеру 1, потрошња горива је начелно мања у односу на први смер, услед висинске разлике између првог и коначног стајалишта.

Карактеристике изабраних конфигурација вештачких неуронских мрежа приказане су у табели 6.2. Коришћена је једна ВНМ са јединичним скривеним слојем и укупно пет са двоструким. Све изабране конфигурације успешно су прошле процес тренирања и по укупно десет мрежа доступно је за сваку разматрану варијанту. Критеријуми за избор мрежа за анализу учинка претходно описаног управљачког алгоритма подразумевали су најниже вредности средњег квадратног одступања – аритметичке средине свих 10 истренираних мрежа и вредности одступања добијене након осредњавања излаза свих 10 мрежа, као и медијане средњег квадратног одступања. Као што је већ у поглављу о учинку процеса тренирања мрежа показано, најбоље перформансе добијају се за најмање вредности задршки спољних параметара и стања мреже. Величина задршки за разматране мреже креће се од 10 до 20, док се за величину задршке стања мреже узимају

вредности од 10 до 30. Број неурона у скривеном слоју једноструке мреже износи 12, док се код мрежа са двоструким скривеним слојем креће од 6 до 10.

У наставку ће бити приказани резултати примене одабраних конфигурација ВНМ на возне циклусе снимљене у реалним експлоатационим условима који подразумевају различите околности у виду оптерећења саобраћаја и возила.

	1	2	3	4	5	6
Варијанта (према 5.4) [-]	1	4	5	5	5	5
Задршка спољних параметара "ID" ("Input Delay")	10	10	20	10	10	10
Задршка стања "FD" ("Feedback Delay")	10	30	20	10	10	10
Број неурона "LS" ("Layer Size")	12	8	8	10	8	6
Средње квадратно одступање [-]	0.02949	0.02904	0.02955	0.02799	0.04032	0.02862
Медијана средњег квадратног одступања [-]	0.02931	0.02919	0.02946	0.02805	0.02787	0.02821
Стандардно одступање [-]	0.00062	0.00059	0.00049	0.00053	0.03959	0.00105
Средње квадратно одступање – осредњени излаз свих мрежа [-]	0.0282	0.02724	0.02728	0.02615	0.02742	0.0269
Број важећих мрежа [-]	10	10	10	10	10	10
број скривених слојева [-]	1	2	2	2	2	2

Табела 6.2: Карактеристике ВНМ изабраних за спровотење валидације управљачке методе

#### 6.2 Анализа резултата управљања хибридним погонским

#### системом применом вештачких неуронских мрежа

Математички модел ХПС дограђен је функцијама за комуникацију и размену потребних података са математичким објектом који представља ВНМ. Након сваког временског инкремента симулације, спроводе се подаци који чине улазне параметре мреже а на излазу исте се добијају вредности расподеле оптерећења које су потребне за прорачун радних параметара ХПС.

Укупно 78 симулација је извршено; 6 возних циклуса је коришћено за укупно 6 различитих конфигурација ВНМ. Најпре су симулације спроведене користећи само једну мрежу по разматраној конфигурацији, и то оне које су показале најмање вредности одступања расподеле оптерећења од тока оптималног управљања. Касније је модел управљања надограђен способношћу да комбинује све успешно истрениране мреже и да за сваки временски инкремент симулације израчуна аритметичку средину расподеле оптерећења свих десет мрежа. На претходно описане 72 симулације ХПС, додају се још шест. Наиме, за сваки возни циклус је спроведена оптимизација управљања користећи методу ДП. На основу свих података, могуће је спровести анализу релативног смањења потрошње горива ХПС у односу на конвенционални погонски систем и установити учинак управљања употребом ВНМ у односу на референтне, оптималне вредности потрошње горива.

На слици 6.1 приказан је дијаграм релативне уштеде у потрошњи горива ХПС у односу на конвенционални случај за репрезентативне возне циклусе у смеру кретања 1.

Приметно је да се највеће уштеде постижу за средње оптерећење у саобраћају, где је постигнута и највећа апсолутна потрошња горива за КПС. У оптималном случају, чак 31,9% уштеде могуће је остварити у динамичким условима вожње који су карактеристични за возни циклус са средњим оптерећењем у саобраћају. Најмање потенцијалне уштеде у потрошњи горива оствариве су у условима ниског оптерећења у саобраћају, када су и вредности апсолутне потрошње горива најмање. У идеалном случају, тада је само 25,2% горива могуће уштедети у односу на КПС. У условима високог оптерећења у саобраћају, у оптималном случају, могуће је уштедети 28,5% горива употребом ХХПС.



Слика 6.1: Поређење релативног смањења потрошње горива ХПС у односу на КПС за три карактеристична циклуса у смеру кретања 1

Вредности релативног смањења потрошње горива за имплементабилни управљачки систем који користи ВНМ очекивано су мање од максимално могућих и крећу се у распону од 69,4% до 86,2% од оних добијених применом ДП.

За возни циклус који репрезентује ниско оптерећење у саобраћају, најбољи учинак у погледу смањене потрошње горива постиже се применом 6. ВНМ (двоструки скривени слој са по 6 неурона, величина задршки улазних параметара/стања мреже од 10/10), уз уштеду од око 20,5%. Незнатно мањи учинак од 20,4% уштеде постиже се са 1. ВНМ (једноструки скривени слој са 12 неурона, величина задршки улазних параметара/стања

мреже од 10/10). На трећем месту по учинку је 3. ВНМ (двоструки скривени слој са по 8 неурона, величина задршки улазних параметара/стања мреже од 20/20), са којом се постиже 20% уштеде у потрошњи горива у односу на КПС. Четврта ВНМ, мрежа са најмањим вредностима средњег квадратног одступања у односу на оптималан ток расподеле оптерећења, тек је четврта по учинку смањења потрошње горива са уштедом од скоро 19%. Незнатно слабије перформансе од 18,7% пружа ВНМ под редним бројем 2 (двоструки скривени слој са по 8 неурона, величина задршки улазних параметара/стања мреже од 10/30, респективно). Значајно слабији учинак у односу на претходне случајеве има 5. ВНМ са релативним смањењем потрошње од 17,5%. Ради се о мрежи са двоструким скривеним слојем од 8 неурона и величинама задршки улазних параметара/стања мреже од 10.

За возни циклус са средњим оптерећењем, вредности смањења потрошње горива ХПС применом алгоритама заснованих на ВНМ крећу се од 24,4% до 27,5%, што представља 76,6% до 86,2% од учинка остваривог применом референтне методе (ДП). Узимајући у обзир све разматране мреже у овом случају, добија се највиша средња вредност учинка ВНМ наспрам оптималне методе од 81,7%. Поредак перформанси ВНМ сличан је као и у случају ниског оптерећења, осим у случају најбољег учинка, где је најбоља мрежа једнострука ВНМ са 12 неурона и величинама задршки од 10. На другом месту је двострука мрежа са 6 неурона.

За возни циклус са високим оптерећењем саобраћаја, средња вредност учинка ВНМ наспрам референтне методе показује благи пад са 81,7% у случају средњег оптерећења на 78,3%. Појединачне вредности крећу се од 70,7% у случају 5. ВНМ (мрежа са двоструким скривеним слојем од 8 неурона и величинама задршки улазних параметара/стања мреже од 10), којом се постиже уштеда у односу на КПС од 20,2%. Максималне перформансе постижу се са 1. ВНМ (једноструком мрежом са 12 неурона), када је омогућена уштеда од 23,9% у односу на КПС (83,5% у односу на оптимално управљање). Треба напоменути да је поредак перформанси исти као и у случају средњег оптерећења саобраћаја.

У наставку следи анализа потрошње горива ХПС применом ВНМ код којих се излазни управљачки сигнал формира на основу аритметичке средине свих расположивих, успешно истренираних модела неуронских мрежа. За сваку разматрану конфигурацију, укупно 10 модела неуронских мрежа употребљено је за формирање сигнала који се прослеђује симулацији ХХПС.

На слици 6.2 приказане су вредности релативне промене потрошње горива предметног XПС у односу на КПС за три карактеристична возна циклуса. Приметно је груписање токова промене потрошње у односу на случај када се управљање формира на основу само једне мреже, оне са најмањим средњим квадратним одступањем од оптималног тока управљања.

Од укупно 6 коришћених мрежа, за 2 долази до погоршања у потрошњи горива за све карактеристичне услове у саобраћају наспрам модела управљачког система који користи само најбоље истренирану мрежу. Наиме, употребом 6. ВНМ (двоструки скривени слој са по 6 неурона, величина задршки улазних параметара/стања мреже од 10/10) и 3. ВНМ (двоструки скривени слој са по 8 неурона, величина задршки улазних параметара/стања мреже од 20/20), долази до повећања потрошње у односу на претходни случај за око 0,8%. Такође, за циклусе са средњим и високим оптерећењем, примена једноструке ВНМ (редни

број 1) доводи до погоршања потрошње горива од 1,4% у односу на управљачки алгоритам који користи само једну истренирану ВНМ. Највеће побољшање потрошње горива добија се за мрежу са редним бројем 5, са вредностима које су за чак 7,9% мање од првобитно добијених.



Слика 6.2: Поређење релативног смањења потрошње горива ХПС у односу на КПС за три карактеристична циклуса у смеру кретања 1 – осредњени излаз свих расположивих, успешно истренираних ВНМ

На слици 6.3 приказан је дијаграм релативне уштеде у потрошњи горива ХПС у односу на конвенционални случај за репрезентативне возне циклусе у смеру кретања 2.

Највеће уштеде постижу се за ниско оптерећење у саобраћају, где су постигнуте највеће вредности средње брзине током кретања возила и уједно највеће вредности средњег позитивног убрзања. Као и у случају возних циклуса у смеру 1, највећа потенцијална уштеда горива остварива је управо у најдинамичнијим условима вожње.

У оптималном случају, чак 37,7% уштеде могуће је остварити у смеру кретања 2. Најмање потенцијалне уштеде у потрошњи горива оствариве су у условима средњег оптерећења у саобраћају, када су и вредности апсолутне потрошње горива КПС најмање. У идеалном случају, тада је само 25,8% горива могуће уштедети у односу на КПС. У условима високог оптерећења у саобраћају, у оптималном случају, могуће је уштедети до 31,3% горива употребом ХХПС. Просечно гледано, за сва три разматрана оптерећења, 31,6% горива могуће је уштедети у смеру кретања 2, док је у смеру 1 оствариво 28,6% уштеде у потрошњи горива.

Вредности релативног смањења потрошње горива у смеру кретања 2 за имплементабилни управљачки систем који користи ВНМ мање су од максимално могућих и крећу се у

распону од 51,5% до 85,3% од оних добијених применом ДП. Аритметичка средина степена оптималности за смер 2 нешто је мања (74,0%) у односу на смер 1 (78,9%), иако су управо у смеру 2 могуће веће уштеде у потрошњи горива.



Слика 6.3: Поређење релативног смањења потрошње горива ХПС у односу на конвенционални погонски систем за три карактеристична циклуса у смеру кретања 2

За возни циклус који репрезентује ниско оптерећење у саобраћају, најбољи учинак у погледу смањене потрошње горива постиже се применом 1. ВНМ (једноструки скривени слој са 12 неурона, величина задршки улазних параметара/стања мреже од 10/10), уз уштеду од 32,2%. На другом месту налази се 6. ВНМ (двоструки скривени слој са по 6 неурона, величина задршки улазних параметара/стања мреже од 10/10), уз уштеду од 31,8%. Остале мреже прате поредак учинка као и у случају ниског оптерећења у смеру 1 кретања возила, са распоном релативног смањења потрошње горива од 31,0% до 28,8%.

За возни циклус са средњим оптерећењем, вредности смањења потрошње горива ХПС применом алгоритама заснованих на ВНМ крећу се од само 13,3% до 18,9%, што представља 51,5% до 73,3% од учинка остваривог применом референтне методе (ДП). Узимајући у обзир све разматране мреже у овом случају, добија се најнижа средња вредност степена оптималности од 65,7%. Поредак перформанси ВНМ исти је као и у случају ниског оптерећења, са значајним падом учинка примећеним за неуронску мрежу број 5.

За возни циклус са високим оптерећењем саобраћаја, средња вредност учинка ВНМ наспрам референтне методе (степена оптималности) показује значајан раст са 65,7% у случају средњег оптерећења на 74,9%. Појединачне вредности крећу се од 67,8% у случају 5.

ВНМ (мрежа са двоструким скривеним слојем од 8 неурона и величинама задршки улазних параметара/стања мреже од 10), којом се постиже уштеда у односу на КПС од 21,2%. Максималне перформансе постижу се са 1. ВНМ (једноструком мрежом са 12 неурона), када је омогућена уштеда од 25,3% у односу на КПС (80,8% у односу на оптимално управљање).



Слика 6.4: Поређење релативног смањења потрошње горива ХПС у односу на КПС за три карактеристична циклуса у смеру кретања 2 – осредњени излаз свих расположивих, успешно истренираних ВНМ

На слици 6.4 приказане су вредности релативне промене потрошње горива предметног XПС у односу на КПС за три карактеристична возна циклуса у смеру кретања 2. Као и у случају смера 1, приметно је груписање токова промене потрошње у односу на случај када се управљање формира на основу само једне мреже по разматраној конфигурацији.

За све мреже у условима ниског оптерећења у саобраћају осим за 6. ВНМ (мрежа са двоструким слојем и по 6 неурона), долази до незнатног побољшања перформанси управљања. За средње оптерећење, долази до погоршања у економичности потрошње горива за све мреже осим за 3. и 5., где долази до значајног побољшања економичности од 16,95% са претходних 13,26%. И у условима високог оптерећења у саобраћају, осредњавањем свих излаза успешно истренираних мрежа и употребом тог сигнала за формирање управљања ХПС, долази до смањења потрошње за случај примене 5. мреже (мрежа са двоструким скривеним слојем од 8 неурона и величинама задршки улазних параметара/стања мреже од 10) и до незнатних промена за остале конфигурације.

## 7 Закључак и смернице за даља истраживања

Процеси глобализације и све интензивнија и просторно распрострањенија подела рада омогућили су незабележени економски раст на измаку 20. и на почетку 21. века. Тиме су стотине милиона становника широм планете избављене из дубоког сиромаштва. Један од кључних елемената у том, од животне важности, процеса јесте мобилност економских чинилаца и сектор транспорта. Због све веће бриге и опасности од ненадокнадивог нарушавања животне средине, велики напори улажу се у изналажењу решења за што ефикаснији транспорт људи и добара, уз што мањи утицај на човекову околину. Један од такође важних фактора у том смеру јесте потреба за конзервацијом енергије. У том смислу, ХПС могу понудити решење за наведене проблеме у блиском и средњем року.

Јавна комунална возила намењена транспорту људи по унапред дефинисаним трасама и терминима нуде додатну погодност у виду централизације путника и ПС који омогућују већа капитална улагања и повећану ефикасност, уз смањење неповољних утицаја на животну средину изражену по кориснику транспортних услуга. Отуда је хибридизација таквих ПС посебно интересантна. Додатно, повећана маса возила погодује примени одређених решења ХПС које карактерише висока специфична снага. Зато је у овој дисертацији разматрана примена ХХПС који се састоји из ХМ (пумпа/мотор) и хидропнеуматског акумулатора. Један од предуслова за примену ХХПС огледа се у оптимизацији функционалних и управљачких параметара таквих система. Посебне потешкоће представљају услови саобраћаја и оптерећења возила који се крећу у широким границама. Једини начин за превазилажење ових проблема огледа се у систематичном и свеобухватном приступу процесима оптимизације.

Са тим у вези, у оквиру предметног истраживања, извршена је вишедневна аквизиција радних параметара КПС на аутобусу који је саобраћао у стварним експлоатационим условима. Анализом и обрадом снимљених података, састављен је скуп возних циклуса у широком спектру услова и оптерећења у саобраћају. Ови подаци омогућили су и калибрацију симулационих модела ПС и веродостојну процену уштеда у потрошњи горива за разматране параметре елемената ХХПС. Поред самог енергетског капацитета и параметара који се односе на топлотне губитке хидро-пнеуматског акумулатора, утврђена је и зависност маса гаса и еластомерне пене на максимално достижни степен корисности ХПС. Наиме, поред тога што је ефикасност таквих акумулатора врло висока и неретко достиже вредности изнад 95%, од пресудне важности за повећање учинка целокупног ХПС у датим експлоатационим околностима и за задате реалне граничне услове је разматрање свих функционалних параметара. Утврђена је веза између свих релевантних параметара хидро-пнеуматског акумулатора и минимално оствариве потрошње горива, чиме је остварена оптимизација функционалних параметара ХХПС.

Анализа утицаја функционалних параметара на минималну потрошњу горива ХХПС извршена је применом ДП, референтне оптимизационе методе за проблеме овог типа. Њен главни недостатак огледа се у немогућности директне примене на разматраном објекту у реалном времену због услова детерминистичког дефинисања домена оптимизације. Због тога је оптимизација управљачких параметара извршена посредством модела заснованих на ВНМ. Изабрано је укупно шест возних циклуса,

снимљених у различитим експлоатационим условима, и за параметре ХХПС добијене функционалном оптимизацијом израчуната је расподела оптерећења за сваки временски инкремент (применом ДП) која минимизује количину потрошеног горива. Ти резултати су потом искоришћени за тренирање ВНМ. Коришћене су различите конфигурације нелинеарне ауторегресивне мреже са спољашњим улазом. Анализом статистичких података добијених поређењем референтног и предвиђеног тока расподеле оптерећења ХПС, установљено је да се најбољи резултати добијају за вредности броја неурона од 6 до 10 за мреже са двоструким скривеним слојем и за мрежу са 12 неурона у једноструком скривеном слоју. Оптималне вредности величине задршке улазних параметара крећу се од 10 до 20, и од 10 до 30 за величину задршке стања мреже. Укупно 10 процеса тренирања извршено је за сваку разматрану конфигурацију ВНМ у циљу смањења утицаја насумично изабраних почетних коефицијената мреже на одступање од референтног тока расподеле оптерећења. Оцена предложене методе формирања управљачког алгоритма извршена је најпре оптимизацијом нових 6 карактеристичних возних циклуса применом ДП. Ти резултати упоређени су са потрошњом горива добијеном применом ХХПС са управљањем заснованим на ВНМ. Применом референтног управљања, просечно гледано за све степене оптерећења у саобраћају, могуће је уштедети 28,6% горива у смеру кретања 1 и до 31,6% у смеру кретања 2. Остварени степен оптималности за најбоље ВНМ износи 83,7% у смеру 1 (23,9% уштеде горива) и 79,8% у смеру кретања 2 (просечно смањење потрошње горива за 25,5%). Коришћењем аритметичке средине расподеле оптерећења за све расположиве ВНМ за дату конфигурацију, долази до побољшања учинка само оних варијанти које нису показале најбоље резултате применом индивидуално најбоље истренираних мрежа.

Највеће оствариве уштеде у потрошњи горива постижу се применом ВНМ са 12 неурона у једноструком скривеном слоју и величинама задршки спољних параметара и стања мреже од 10/10, респективно. Једино одступање јавља се за најмање оптерећење у саобраћају у смеру кретања 1, где је ВНМ са по 6 неурона у двоструком скривеном слоју на првом месту са незнатно већом уштедом.

Будућа истраживања на тему оптимизације ХПС концентрисаће се на смањење разлике између оствариве и максимално могуће уштеде у потрошњи горива. У спроведеном истраживању установљено је да се највећи учинак у погледу минимизације потрошње горива добија применом модела ВНМ који не постиже најниже вредности средњег квадратног одступања од оптималног тока расподеле оптерећења. Циљ ће бити анализирати и одредити утицај одступања управљачког параметра од оптималног тока на пропуштену уштеду горива и идентификација стања у којима та одступања највише утичу на потенцијал смањења потрошње. Тиме ће бити омогућено унапређење у процесу тренирања ВНМ са циљем повећања степена оптималности управљачког система.

Такође, требало би извршити анализу утицаја избора параметара за улазне величине које се користе за формирање управљачког сигнала ВНМ. Број доступних променљивих, као и изведених величина које се могу формирати на основу њих, далеко је већи од параметара који су коришћени у фазама тренирања и примене ВНМ.

На крају, уколико претходна истраживања не доведу до значајног повећања степена оптималности управљачког система, требало би испитати могућност примене различитих модела ВНМ на основу тренутних услова оптерећења у саобраћају и самог возила. Наиме, пажљивим избором и ограничавањем скупа података који се користе за тренирање мрежа, могло би се формирати неколико различитих, за сваку карактеристичну класу возних циклуса високо-специјализованих, управљачких модела. Током саме експлоатације ХПС, анализом параметара који описују стање оптерећења у саобраћају, могућа је измена примењене ВНМ и потенцијално побољшање у учинку система.

## Литература

- S. [ORNL] (ORCID:000000188604535) Davis and R. G. [ORNL] Boundy, "Transportation Energy Data Book: Edition 38," United States, Feb. 2020. doi: 10.2172/1606919.
- [2] R. L. Bradley and R. W. Fulmer, *Energy: the master resource: an introduction to the history, technology, economics, and public policy of energy.* New York: HarperCollins, 2004.
- [3] "International Energy Outlook 2019," p. 85.
- [4] Q. Xin and C. F. Pinzon, "Improving the environmental performance of heavy-duty vehicles and engines: key issues and system design approaches," in *Alternative Fuels and Advanced Vehicle Technologies for Improved Environmental Performance*, Elsevier, 2014, pp. 225–278. doi: 10.1533/9780857097422.2.225.
- [5] T. Ott, F. Zurbriggen, C. Onder, and L. Guzzella, "Cycle-averaged efficiency of hybrid electric vehicles," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 227, no. 1, pp. 78–86, Jan. 2013, doi: 10.1177/0954407012447508.
- [6] A. Sciarretta and A. Vahidi, Energy-Efficient Driving of Road Vehicles: Toward Cooperative, Connected, and Automated Mobility. Cham: Springer International Publishing, 2020. doi: 10.1007/978-3-030-24127-8.
- [7] Z. Wadud, D. MacKenzie, and P. Leiby, "Help or hindrance? The travel, energy and carbon impacts of highly automated vehicles," *Transportation Research Part A: Policy and Practice*, vol. 86, pp. 1–18, Apr. 2016, doi: 10.1016/j.tra.2015.12.001.
- [8] M. R. Cuddy and K. B. Wipke, "Analysis of the Fuel Economy Benefit of Drivetrain Hybridization," Feb. 1997, p. 970289. doi: 10.4271/970289.
- [9] S. D. Farrall and R. P. Jones, "Energy management in an automotive electric/heat engine hybrid powertrain using fuzzy decision making," in *Proceedings of 8th IEEE International Symposium on Intelligent Control*, Chicago, IL, USA, 1993, pp. 463–468. doi: 10.1109/ISIC.1993.397669.
- [10] M. Kokkolaras *et al.*, "Design Under Uncertainty and Assessment of Performance Reliability of a Dual-Use Medium Truck with Hydraulic-Hybrid Powertrain and Fuel Cell Auxiliary Power Unit," Apr. 2005, pp. 2005-01–1396. doi: 10.4271/2005-01-1396.
- [11] F. Tavares, R. Johri, A. Salvi, S. Baseley, and Z. Filipi, "Hydraulic Hybrid Powertrain-In-the-Loop Integration for Analyzing Real-World Fuel Economy and Emissions Improvements," Sep. 2011, pp. 2011-01–2275. doi: 10.4271/2011-01-2275.
- [12] Z. Filipi and Y. J. Kim, "Hydraulic Hybrid Propulsion for Heavy Vehicles: Combining the Simulation and Engine-In-the-Loop Techniques to Maximize the Fuel Economy and Emission Benefits," *Oil & Gas Science and Technology*, vol. 65, no. 1, pp. 155–178, Jan. 2010, doi: 10.2516/ogst/2009024.
- [13] P. Drozdz, "Hybrid Refuse Truck Feasibility Study," Transport Development Centre, Montreal, Quebec, TP 14431E, Aug. 2005.
- [14] Chan-Chiao Lin, Jun-Mo Kang, J. W. Grizzle, and Huei Peng, "Energy management strategy for a parallel hybrid electric truck," in *Proceedings of the 2001 American Control Conference. (Cat. No.01CH37148)*, Arlington, VA, USA, 2001, pp. 2878–2883 vol.4. doi: 10.1109/ACC.2001.946337.
- [15] J. Pu, C. Yin, and J. Zhang, "Fuel optimal control of parallel hybrid electric vehicles," Front. Mech. Eng. China, vol. 3, no. 3, pp. 337–342, Sep. 2008, doi: 10.1007/s11465-008-0057-7.
- [16] C.-C. Lin *et al.*, "Integrated, Feed-Forward Hybrid Electric Vehicle Simulation in SIMULINK and its Use for Power Management Studies," Mar. 2001, pp. 2001-01–1334. doi: 10.4271/2001-01-1334.
- [17] O. Sundström, D. Ambühl, and L. Guzzella, "On Implementation of Dynamic Programming for Optimal Control Problems with Final State Constraints," *Oil & Gas Science and Technology*, vol. 65, no. 1, pp. 91–102, Jan. 2010, doi: 10.2516/ogst/2009020.

- [18] B. Wu, C.-C. Lin, Z. Filipi, H. Peng, and D. Assanis, "Optimal Power Management for a Hydraulic Hybrid Delivery Truck," *Vehicle System Dynamics*, vol. 42, no. 1–2, pp. 23–40, Dec. 2004, doi: 10.1080/00423110412331291562.
- [19] X. Lin, A. Ivanco, and Z. Filipi, "Optimization of Rule-Based Control Strategy for a Hydraulic-Electric Hybrid Light Urban Vehicle Based on Dynamic Programming," SAE Int. J. Alt. Power., vol. 1, no. 1, pp. 249–259, Apr. 2012, doi: 10.4271/2012-01-1015.
- [20] Chan-Chiao Lin, Huei Peng, J. W. Grizzle, and Jun-Mo Kang, "Power management strategy for a parallel hybrid electric truck," *IEEE Trans. Contr. Syst. Technol.*, vol. 11, no. 6, pp. 839–849, Nov. 2003, doi: 10.1109/TCST.2003.815606.
- [21] P. Elbert, S. Ebbesen, and L. Guzzella, "Implementation of Dynamic Programming for \$n\$-Dimensional Optimal Control Problems With Final State Constraints," *IEEE Trans. Contr. Syst. Technol.*, vol. 21, no. 3, pp. 924–931, May 2013, doi: 10.1109/TCST.2012.2190935.
- [22] J. Scordia, "Approche systématique de l'optimisation du dimensionnement et de l'élaboration de lois de gestion d'énergie de véhicules hybrides."
- [23] K. Aoki, S. Kuroda, S. Kajiwara, H. Sato, and Y. Yamamoto, "Development of Integrated Motor Assist Hybrid System: Development of the 'Insight', a Personal Hybrid Coupe," Jun. 2000, pp. 2000-01–2216. doi: 10.4271/2000-01-2216.
- [24] M. Duoba, H. Ng, and R. Larsen, "Characterization and Comparison of Two Hybrid Electric Vehicles (HEVs) - Honda Insight and Toyota Prius," Mar. 2001, pp. 2001-01–1335. doi: 10.4271/2001-01-1335.
- [25] "Hydraulic Hybrids from Rexroth: Hydrostatic Regenerative Braking System HRB." Bosch Rexroth Corporation.
- [26] Technologies and Approaches to Reducing the Fuel Consumption of Medium- and Heavy-Duty Vehicles. Washington, D.C.: National Academies Press, 2010. doi: 10.17226/12845.
- [27] M. Kitanovic, S. Popovic, N. Miljic, M. Cvetic, M. Tomic, and P. Mrdja, "HYDRAULIC HYBRID TECHNOLOGY REVIEW – PERSPECTIVES AND BENEFITS OF ITS IMPLEMENTATION ON PUBLIC TRANSPORTATION VEHICLES," Sokobanja, Serbia, Oct. 2011, p. 9.
- [28] T. Pels and C. Kaup, "Micro, Mild, and Full Hybrids," in *Encyclopedia of Automotive Engineering*, D. Crolla, D. E. Foster, T. Kobayashi, and N. Vaughan, Eds. Chichester, UK: John Wiley & Sons, Ltd, 2014, pp. 1–6. doi: 10.1002/9781118354179.auto046.
- [29] J. Kargul, A. Moskalik, K. Newman, D. Barba, and J. Rockwell, "Design and Demonstration of EPA's Integrated Drive Module for Commercial Series Hydraulic Hybrid Trucks and Buses," *SAE Int. J. Commer. Veh.*, vol. 8, no. 2, pp. 549–567, Sep. 2015, doi: 10.4271/2015-01-2850.
- [30] J. Albers, E. Meissner, and S. Shirazi, "Lead-acid batteries in micro-hybrid vehicles," *Journal* of Power Sources, vol. 196, no. 8, pp. 3993–4002, Apr. 2011, doi: 10.1016/j.jpowsour.2010.11.094.
- [31] B. L. Van Batavia, "Hydraulic Hybrid Vehicle Energy Management System," 2009. doi: 10.4271/2009-01-2834.
- [32] F. Tavares, R. Johri, and Z. Filipi, "Simulation Study of Advanced Variable Displacement Engine Coupled to Power-Split Hydraulic Hybrid Powertrain," *J. Eng. Gas Turbines Power*, vol. 133, no. 12, p. 122803, 2011, doi: 10.1115/1.4004073.
- [33] Z. Filipi, "Hydraulic and pneumatic hybrid powertrains for improved fuel economy in vehicles," in *Alternative Fuels and Advanced Vehicle Technologies for Improved Environmental Performance*, Elsevier, 2014, pp. 505–540. doi: 10.1533/9780857097422.2.505.
- [34] R. Johri, S. Baseley, and Z. Filipi, "Simultaneous Optimization of Supervisory Control and Gear Shift Logic for a Parallel Hydraulic Hybrid Refuse Truck Using Stochastic Dynamic Programming," in ASME 2011 Dynamic Systems and Control Conference and Bath/ASME Symposium on Fluid Power and Motion Control, Volume 1, Arlington, Virginia, USA, 2011, pp. 99–106. doi: 10.1115/DSCC2011-6172.
- [35] R. E. Bellman and S. E. Dreyfus, *Applied Dynamic Programming*. Princetown University Press, 1962.

- [36] Z. Filipi *et al.*, "Combined optimisation of design and power management of the hydraulic hybrid propulsion system for the 6? 6 medium truck," *IJHVS*, vol. 11, no. 3/4, p. 372, 2004, doi: 10.1504/IJHVS.2004.005458.
- [37] L. Tao, Z. Jincheng, W. Shuwen, and G. Fangde, "Logic Threshold Based Energy Control Strategy for Parallel Hydraulic Hybrid Vehicles," *RJASET*, vol. 6, no. 13, pp. 2339–2344, Aug. 2013, doi: 10.19026/rjaset.6.3705.
- [38] C.-C. Lin, Z. Filipi, L. Louca, H. Peng, D. Assanis, and J. Stein, "Modelling and control of a medium-duty hybrid electric truck," *IJHVS*, vol. 11, no. 3/4, p. 349, 2004, doi: 10.1504/IJHVS.2004.005455.
- [39] A. Brahma, B. Glenn, Y. Guezennec, T. Miller, G. Rizzoni, and G. Washington, "Modeling, performance analysis and control design of a hybrid sport-utility vehicle," in *Proceedings of the* 1999 IEEE International Conference on Control Applications (Cat. No.99CH36 328), Kohala Coast, HI, USA, 1999, vol. 1, pp. 448–453. doi: 10.1109/CCA.1999.806677.
- [40] J. Won and R. Langari, "Fuzzy torque distribution control for a parallel hybrid vehicle," *Expert Systems*, vol. 19, no. 1, pp. 4–10, Feb. 2002, doi: 10.1111/1468-0394.00184.
- [41] B. M. Baumann, G. Washington, B. C. Glenn, and G. Rizzoni, "Mechatronic design and control of hybrid electric vehicles," *IEEE/ASME Trans. Mechatron.*, vol. 5, no. 1, pp. 58–72, Mar. 2000, doi: 10.1109/3516.828590.
- [42] A. A. Abdelsalam and S. Cui, "A Fuzzy Logic Global Power Management Strategy for Hybrid Electric Vehicles Based on a Permanent Magnet Electric Variable Transmission," *Energies*, vol. 5, no. 4, pp. 1175–1198, Apr. 2012, doi: 10.3390/en5041175.
- [43] G. Paganelli, T. M. Guerra, S. Delprat, J.-J. Santin, M. Delhom, and E. Combes, "Simulation and assessment of power control strategies for a parallel hybrid car," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 214, no. 7, pp. 705–717, Jul. 2000, doi: 10.1243/0954407001527583.
- [44] L. Xu, G. Cao, J. Li, F. Yang, L. Lu, and M. Ouyang, "Equivalent Consumption Minimization Strategies of Series Hybrid City Buses," in *Energy Management*, F. Macia, Ed. InTech, 2010. doi: 10.5772/39529.
- [45] G. Paganelli, "General supervisory control policy for the energy optimization of chargesustaining hybrid electric vehicles," *JSAE Review*, vol. 22, no. 4, pp. 511–518, Oct. 2001, doi: 10.1016/S0389-4304(01)00138-2.
- [46] J. Park and J.-H. Park, "Development of equivalent fuel consumption minimization strategy for hybrid electric vehicles," *Int.J Automot. Technol.*, vol. 13, no. 5, pp. 835–843, Aug. 2012, doi: 10.1007/s12239-012-0084-6.
- [47] P. Pisu and G. Rizzoni, "A Supervisory Control Strategy for Series Hybrid Electric Vehicles with Two Energy Storage Systems," in 2005 IEEE Vehicle Power and Propulsion Conference, Chicago, IL, USA, 2005, pp. 65–72. doi: 10.1109/VPPC.2005.1554534.
- [48] A. Sciarretta, M. Back, and L. Guzzella, "Optimal Control of Parallel Hybrid Electric Vehicles," *IEEE Trans. Contr. Syst. Technol.*, vol. 12, no. 3, pp. 352–363, May 2004, doi: 10.1109/TCST.2004.824312.
- [49] T. O. Deppen, A. G. Alleyne, K. A. Stelson, and J. J. Meyer, "Predictive Energy Management for Parallel Hydraulic Hybrid Passenger Vehicle," in ASME 2010 Dynamic Systems and Control Conference, Volume 2, Cambridge, Massachusetts, USA, 2010, pp. 185–192. doi: 10.1115/DSCC2010-4105.
- [50] T. O. Deppen, A. G. Alleyne, K. Stelson, and J. Meyer, "A model predictive control approach for a parallel hydraulic hybrid powertrain," in *Proceedings of the 2011 American Control Conference*, San Francisco, CA, Jun. 2011, pp. 2713–2718. doi: 10.1109/ACC.2011.5991128.
- [51] S. A. Schepmann, "Ultracapacitor Heavy Hybrid Vehicle: Model Predictive Control Using Future Information to Improve Fuel Consumption," p. 178.
- [52] L. Marescot *et al.*, "Complex decisions made simple: a primer on stochastic dynamic programming," *Methods Ecol Evol*, vol. 4, no. 9, pp. 872–884, Sep. 2013, doi: 10.1111/2041-210X.12082.

- [53] R. Johri and Z. Filipi, "Low-Cost Pathway to Ultra Efficient City Car: Series Hydraulic Hybrid System with Optimized Supervisory Control," *SAE Int. J. Engines*, vol. 2, no. 2, pp. 505– 520, Sep. 2009, doi: 10.4271/2009-24-0065.
- [54] R. Johri, A. Salvi, and Z. Filipi, "Optimal Energy Management for a Hybrid Vehicle Using Neuro-Dynamic Programming to Consider Transient Engine Operation," in ASME 2011 Dynamic Systems and Control Conference and Bath/ASME Symposium on Fluid Power and Motion Control, Volume 2, Arlington, Virginia, USA, 2011, pp. 279–286. doi: 10.1115/DSCC2011-6138.
- [55] T.-K. Lee and Z. S. Filipi, "Representative Midwestern US Cycles: Synthesis and Applications," *Oil Gas Sci. Technol. Rev. IFP Energies nouvelles*, vol. 68, no. 1, pp. 117–126, Jan. 2013, doi: 10.2516/ogst/2012045.
- [56] H. B. Demuth, M. H. Beale, O. De Jess, and M. T. Hagan, *Neural Network Design*, 2nd ed. Stillwater, OK, USA: Martin Hagan, 2014.
- [57] R. Aris, *Mathematical Modelling Techniques*. New York: Dover Publications, 1995.
- [58] "Tehnička specifikacija IK 206 (MAN D2066, Voith DIWA.5)." Ikarbus, 2016. [Online]. Available: http://ikarbus.rs/images/Proizvodi/IK-206/TS-IK2062016SR.pdf
- [59] "Ikarbus IK 206." [Online]. Available: http://ikarbus.rs/images/Galerije/IK-206/IK206-1171024x500.jpg
- [60] Truck Bus Control and Communications Network Committee, "Vehicle Application Layer," SAE International. doi: 10.4271/J1939/71\_200412.
- [61] M. Junger, "Introduction to J1939," p. 11.
- [62] "ISO 11898-1 Road Vehicles Controller Area Network (CAN) Part 1: Data link layer and physical signalling." ISO.
- [63] "ISO 11898-2 Road Vehicles Controller Area Network (CAN) Part 2: High-speed medium access unit." ISO.
- [64] "NI LabVIEW for CompactRIO Developer's Guide." National Instruments. [Online]. Available: https://www.ni.com/en-rs/shop/compactrio/compactrio-developers-guide.html
- [65] "NI cRIO-9025 User Manual and Specifications." National Instruments. [Online]. Available: https://www.ni.com/pdf/manuals/375 490d.pdf
- [66] "NI cRIO-9111/9112/9113/9114/9116/9118 User Manual and Specifications." National Instruments. [Online]. Available: https://www.ni.com/pdf/manuals/375079e.pdf
- [67] "NI 9853 Getting Started Guide National Instruments." National Instruments. [Online]. Available: https://www.ni.com/pdf/manuals/371453f.pdf
- [68] "NI-CAN Hardware and Software manual." National Instruments. [Online]. Available: https://www.ni.com/pdf/manuals/370 289t.pdf
- [69] "GPS 18x Technical Specifications." Garmin International, Inc., Oct. 2011. [Online]. Available: https://static.garmin.com/pumac/GPS\_18x\_Tech\_Specs.pdf
- [70] "cRIO-9025 CompactRIO Controller." [Online]. Available: https://www.ni.com/en-rs/support/model.crio-9025.html
- [71] "cRIO-9118 CompactRIO Chassis." [Online]. Available: https://www.ni.com/en-rs/support/model.crio-9118.html
- [72] "NI 9853 C Series CAN Interface Module." [Online]. Available: https://www.ni.com/en-rs/support/model.ni-9853.html
- [73] R. Bitter, T. Mohiuddin, and M. Nawrocki, *LabView advanced programming techniques*, 2nd ed. Boca Raton, FL: CRC Press/Taylor & Francis Group, 2007.
- [74] "NMEA 0183 Standard For Interfacing Marine Electronic Devices." NMEA, 2002.
- [75] "NI-VISA User Manual." National Instruments. [Online]. Available: https://www.ni.com/pdf/manuals/370423a.pdf
- [76] M. Kitanovic, N. Miljic, S. Popovic, and P. Mrdja, "Onboard Bus Powertrain Parameter and Position Datalogging Solution for Driving-Cycle Determination and Energy Efficiency Analysis," presented at the NIDays 2011, Nov. 2011.
- [77] T. G. Farr et al., "The Shuttle Radar Topography Mission," Rev. Geophys., vol. 45, no. 2, p. RG2004, May 2007, doi: 10.1029/2005RG000183.

- [78] Earth Resources Observation And Science (EROS) Center, "Shuttle Radar Topography Mission (SRTM) 1 Arc-Second Global." U.S. Geological Survey, 2017. doi: 10.5066/F7PR7TFT.
- [79] A. M. Gross, "Confidence intervals for bisquare regression estimates," *Journal of the American Statistical Association*, vol. 72, no. 358, pp. 341–354, 1977.
- [80] W. S. Cleveland, "Robust locally weighted regression and smoothing scatterplots," *Journal of the American statistical association*, vol. 74, no. 368, pp. 829–836, 1979.
- [81] H. B. Nielsen, S. N. Lophaven, and J. Søndergaard, *DACE A Matlab Kriging Toolbox*. Informatics and Mathematical Modelling, Technical University of Denmark, DTU, 2002.
- [82] M. Kitanović, P. Mrđa, V. Petrović, N. Miljić, S. J. Popović, and M. Tomić, "A SIMULATION STUDY OF FUEL ECONOMY IMPROVEMENT POTENTIALS OF A TRANSIT BUS," Belgrade, Serbia, Apr. 2013, p. 12.
- [83] D. E. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, 1st ed. USA: Addison-Wesley Longman Publishing Co., Inc., 1989.
- [84] J. Carr, "An Introduction to Genetic Algorithms," p. 40.
- [85] K. E. Kinnear, Ed., *Advances in genetic programming*, 2. print. Cambridge, Mass.: MIT Press, 1994.
- [86] A. Hassanat, K. Almohammadi, E. Alkafaween, E. Abunawas, A. Hammouri, and V. B. S. Prasath, "Choosing Mutation and Crossover Ratios for Genetic Algorithms—A Review with a New Dynamic Approach," *Information*, vol. 10, no. 12, p. 390, Dec. 2019, doi: 10.3390/info10120390.
- [87] E. Lindzus and B. R. Ag, "HRB Hydrostatic Regenerative Braking System: The Hydraulic Hybrid Drive from Bosch Rexroth," p. 7.
- [88] "Axial piston variable pump A4VSO Series 1x and 3x Rexroth." Bosch Rexroth AG.
- [89] A. Pourmovahed, N. H. Beachley, and F. J. Fronczak, "Modeling of a Hydraulic Energy Regeneration System: Part I—Analytical Treatment," J. Dyn. Sys., Meas., Control, vol. 114, no. 1, p. 155, 1992, doi: 10.1115/1.2896497.
- [90] A. Pourmovahed and D. R. Otis, "An Experimental Thermal Time-Constant Correlation for Hydraulic Accumulators," J. Dyn. Sys., Meas., Control, vol. 112, no. 1, p. 116, 1990, doi: 10.1115/1.2894128.
- [91] A. Pourmovahed, "Energy storage capacity of gas-charged hydraulic accumulators," presented at the 23rd Thermophysics, Plasmadynamics and Lasers Conference, San Antonio,CA,U.S.A., Jun. 1988. doi: 10.2514/6.1988-2656.
- [92] R. W. Hamming, *Numerical methods for scientists and engineers*, 2nd ed. New York: Dover, 1986.
- [93] G. Lino, *Vehicle propulsion systems: introduction to modeling and optimization*, 3rd ed. New York: Springer, 2013.
- [94] "Datasheet 125 V Heavy Transportation Module BMOD0063 P125." Maxwell Technologies.
- [95] D. E. Kirk, *Optimal Control Theory: An Introduction*. Dover Publications, 2004. [Online]. Available: https://books.google.rs/books?id=fCh2SAtWIdwC
- [96] K. H. Johansson, "Lecture 21 Dynamic Programming." [Online]. Available: https://people.kth.se/~kallej/eecs291e/lecture21.pdf
- [97] P.R. Kumar, Dynamic programming. Department of ECE, University of Illinois, USA.
   [Online]. Available: http://cesg.tamu.edu/wp-content/uploads/2014/09/Dynamic-Programming-Chapter1.pdf
- [98] O. Sundstrom and L. Guzzella, "A generic dynamic programming Matlab function," in 2009 IEEE International Conference on Control Applications, St. Petersburg, Russia, Jul. 2009, pp. 1625–1630. doi: 10.1109/CCA.2009.5281131.
- [99] L. Von Mises, *Human action: a treatise on economics*, Scholar's ed. Auburn, Ala: Ludwig Von Mises Institute, 1998.
- [100] G. Reisman, *Capitalism: a treatise on economics*. Laguna Hills, Calif: TJS Books, 1998.

- [101] A. Pourmovahed, N. H. Beachley, and F. J. Fronczak, "Modeling of a Hydraulic Energy Regeneration System: Part II—Experimental Program," J. Dyn. Sys., Meas., Control, vol. 114, no. 1, p. 160, 1992, doi: 10.1115/1.2896498.
- [102] B. J. McBride, M. J. Zehe, and S. Gordon, "NASA Glenn Coefficients for Calculating Thermodynamic Properties of Individual Species," p. 297, 2002.
- [103] P. Kim, *MATLAB deep learning: with machine learning, neural networks and artificial intelligence.* Berkeley, California: Apress, 2017.
- [104] F. Rosenblatt, "The perceptron: A probabilistic model for information storage and organization in the brain.," *Psychological Review*, vol. 65, no. 6, pp. 386–408, 1958, doi: 10.1037/h0042519.
- [105] D. E. Rumelhart, G. E. Hintont, and R. J. Williams, "Learning representations by back-propagating errors," p. 4, 1986.
- [106] Raul Rojas, Neural Networks A Systematic Introduction. Springer, 1996.
- [107] Mark Hudson Beale, Martin T. Hagan, and Howard B. Demuth, "Deep Learning Toolbox Reference." The MathWorks, Inc., Sep. 2019.
- [108] D. Nguyen and B. Widrow, "Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights," in 1990 IJCNN International Joint Conference on Neural Networks, San Diego, CA, USA, 1990, pp. 21–26 vol.3. doi: 10.1109/IJCNN.1990.137819.

## А.Прилог

У наставку су приказани основни подаци о снимљеним циклусима у табеларној форми, као и дијаграми са расподелом убрзања и маса возила појединачних циклуса.

Табела А.1	Снимљени возни циклуси у смеру 1 - апсолутне вредности параметара
Табела А.2	Снимљени возни циклуси у смеру 2 - апсолутне вредности параметара
Табела А.3	Снимљени возни циклуси у смеру 1 - средња квадратна одступања параметара
Табела А.4	Снимљени возни циклуси у смеру 2 - средња квадратна одступања параметара
Табела А.5	Основни параметри обрађених циклуса са редним бројем категорија 1 и 2 за смер 1
Табела А.6	Основни параметри обрађених циклуса са редним бројем категорија 1 и 2 за смер 2

Слике А.1 до А.24 Расподела убрзања и масе возила за снимљене возне циклусе

У наставку је дат опис свих релевантних величина:

 $t_{0}\,$  - почетак циклуса

t<sub>f</sub> - крај циклуса

 $\Delta t$  - време трајања циклуса

 $v_{\scriptscriptstyle pos}\,$  - средња брзина у фазама кретања возила

 $a_{\scriptscriptstyle pos}\,$  - средње позитивно убрзање у фазама кретања возила

 $a_{\rm neg}\,$  - средње негативно убрзање у фазама кретања возила

 $m_v\,$  - средња маса возила

*m*<sub>f</sub> - укупна потрошена количина горива

t<sub>stat</sub> - укупно време стајања возила

 $\delta_{\scriptscriptstyle stat}\,$ - укупни удео стајања возила у циклусу

 $\sigma_{\it apos}\,$  - средње квадратно одступање позитивног убрзања у фазама кретања возила

 $\sigma_{\scriptscriptstyle aneg}\,$  - средње квадратно одступање негативног убрзања у фазама кретања возила

 $\sigma_{\it mv}\,$  - средње квадратно одступање масе возила

шифра циклуса	t <sub>0</sub>	$t_f$	$\Delta t$	V <sub>pos</sub>	$a_{pos}$	a <sub>neg</sub>	$m_{v}$	m <sub>f</sub>	t <sub>stat</sub>	$\delta_{\scriptscriptstyle stat}$
	[h:min:s]	[h:min:s]	[s]	[m/s]	$[m/s^2]$	$[m/s^2]$	[t]	[kg]	[s]	[%]
270 001_02_1	7:31:52	8:17:01	2708	6.265	0.486	-0.512	17.8	6.985	655.2	24.2
270 001_04_1	9:18:18	10:08:47	3028	5.645	0.486	-0.487	17.6	7.336	753.4	24.9
270 001_06_1	11:08:34	11:53:45	2710	6.186	0.468	-0.509	18.5	7.149	646	23.8
270 001_08_1	12:57:07	13:45:50	2923	5.819	0.486	-0.505	19.1	7.321	729.8	25.0
270 001_10_1	14:54:35	15:42:36	2880	5.726	0.451	-0.460	19.0	6.674	617.4	21.4
270 001_12_1	16:47:48	17:42:24	3276	5.296	0.416	-0.445	17.5	6.919	831.8	25.4
270 001_14_1	18:41:42	19:23:35	2512	6.342	0.424	-0.457	18.4	5.783	507.8	20.2
270 001_16_1	20:34:45	21:13:29	2324	6.941	0.432	-0.457	19.6	5.451	489.4	21.1
290 001_01_1	7:31:37	8:15:24	2626	6.400	0.499	-0.481	17.9	7.004	628	23.9
290 001_03_1	9:19:24	10:03:06	2622	6.384	0.467	-0.506	17.0	6.851	623.4	23.8
290 001_05_1	11:07:54	11:52:41	2688	6.165	0.456	-0.524	19.0	7.035	619.6	23.1
290 001_07_1	12:58:28	13:47:49	2962	5.902	0.488	-0.521	18.3	7.920	797	26.9
290 001_09_1	14:54:10	15:47:46	3215	5.678	0.421	-0.445	20.7	7.237	941	29.3
290 001_11_1	16:49:58	17:43:37	3219	5.442	0.450	-0.470	18.9	6.677	874.8	27.2
290 001 13 1	18:41:34	19:22:49	2475	6.525	0.444	-0.477	20.0	6.078	521.2	21.1
310 001_01_1	13:37:11	14:18:53	2515	6.604	0.460	-0.534	16.6	6.164	580.2	23.1
330 001_01_1	15:00:26	15:40:40	2416	7.018	0.464	-0.508	18.1	6.418	573	23.7
330 001_03_1	16:34:34	17:13:18	2327	6.999	0.442	-0.496	16.5	6.013	497.2	21.4
330 001_05_1	18:08:19	18:49:09	2454	6.748	0.453	-0.518	19.0	6.535	565	23.0
330 001_07_1	19:42:27	20:20:49	2304	6.840	0.453	-0.459	18.0	6.037	441	19.1
350 001_01_1	7:31:42	8:17:28	2747	6.053	0.472	-0.495	18.0	7.458	620	22.6
350 001_03_1	9:17:24	10:03:37	2773	5.933	0.512	-0.486	18.4	6.887	594	21.4
350 001_05_1	11:08:11	11:53:41	2730	6.373	0.518	-0.522	19.2	7.312	720	26.4
350 001_07_1	12:59:26	13:45:55	2789	6.318	0.526	-0.573	18.1	8.050	765.6	27.5
350 001_09_1	14:53:37	15:40:34	2818	6.044	0.438	-0.453	20.8	6.516	684.8	24.3
350 001_11_1	16:49:06	17:37:52	2927	5.859	0.449	-0.465	17.5	6.667	739.8	25.3
350 001_13_1	18:39:57	19:23:52	2635	6.384	0.476	-0.487	19.4	6.500	612.8	23.3
350 001_15_1	20:33:00	21:15:55	2574	6.602	0.436	-0.436	17.6	5.928	629.8	24.5
360 001_02_1	7:32:43	8:23:43	3059	5.764	0.492	-0.503	18.5	8.008	836.6	27.3
360 001_04_1	9:21:02	10:05:16	2654	6.425	0.524	-0.542	17.8	7.473	657.2	24.8
360 001_06_1	11:04:59	11:53:54	2935	5.930	0.507	-0.515	18.6	7.392	742.4	25.3
360 001_08_1	12:57:01	13:44:33	2851	6.197	0.545	-0.578	18.3	8.148	778.4	27.3
360 001_10_1	14:54:56	15:46:44	3108	5.764	0.445	-0.468	19.6	7.017	883.8	28.4
360 001_12_1	16:49:24	17:43:02	3217	5.302	0.457	-0.422	18.8	6.942	802.2	24.9
370 001_01_1	18:41:11	19:26:41	2735	5.953	0.413	-0.408	17.7	6.098	590.6	21.6
370 001_03_1	20:33:34	21:15:12	2503	6.464	0.449	-0.442	16.8	6.004	521.4	20.8

Табела А.1: Снимљени возни циклуси у смеру 1 - апсолутне вредности

шифра циклуса	t <sub>0</sub>	t <sub>f</sub>	$\Delta t$	V <sub>pos</sub>	$a_{pos}$	a <sub>neg</sub>	m <sub>v</sub>	m <sub>f</sub>	t <sub>stat</sub>	$\delta_{\scriptscriptstyle stat}$
	[h:min:s]	[h:min:s]	[s]	[m/s]	$[m/s^2]$	$[m/s^2]$	[t]	[kg]	[s]	[%]
270 001_01_2	6:39:05	7:15:38	2193	6.919	0.487	-0.488	18.0	5.228	334	15.2
$270001\_03\_2$	8:24:24	9:07:11	2566	6.335	0.499	-0.505	17.6	5.923	532.2	20.7
270 001_05_2	10:10:58	10:52:50	2512	6.099	0.464	-0.468	19.5	5.471	396.2	15.8
270 001_07_2	12:01:48	12:45:56	2648	6.048	0.514	-0.492	17.5	5.976	509.6	19.2
270 001_09_2	13:52:09	14:36:47	2678	6.212	0.444	-0.477	17.7	5.472	601.4	22.5
270 001_11_2	15:51:15	16:36:56	2740	6.089	0.433	-0.472	19.9	5.575	624.8	22.8
270 001_13_2	17:47:56	18:32:13	2657	6.125	0.448	-0.475	18.4	5.424	552.2	20.8
270 001_15_2	19:39:18	20:20:50	2491	6.418	0.420	-0.443	20.1	4.836	486.2	19.5
290 001_02_2	8:24:36	9:07:03	2546	6.263	0.484	-0.506	18.2	5.552	494	19.4
290 001_04_2	10:11:47	10:57:35	2747	6.221	0.527	-0.516	19.5	6.099	673	24.5
290 001_06_2	12:01:28	12:50:11	2924	5.940	0.483	-0.478	17.8	6.318	728	24.9
290 001_08_2	13:54:52	14:43:09	2897	5.729	0.429	-0.447	18.5	5.512	642	22.2
290 001_10_2	15:48:53	16:48:36	3583	5.262	0.463	-0.489	18.9	6.651	1100	30.7
$290001\_12\_2$	17:46:14	18:32:24	2770	6.067	0.525	-0.547	19.0	6.176	612.2	22.1
290 001_14_2	19:38:47	20:23:10	2662	6.259	0.438	-0.483	17.3	5.303	605.4	22.7
330 001_02_2	15:46:33	16:26:36	2406	6.743	0.434	-0.535	17.4	5.150	478.4	19.9
330 001_04_2	17:20:50	18:02:21	2494	6.744	0.449	-0.528	17.6	5.523	566	22.7
330 001_06_2	18:53:03	19:36:20	2599	6.400	0.457	-0.487	18.0	5.618	562.4	21.6
330 001_08_2	20:27:38	21:07:21	2386	6.700	0.448	-0.516	17.9	5.291	459.8	19.3
350 001_02_2	8:24:19	9:08:16	2637	6.158	0.500	-0.489	18.3	6.136	538.4	20.4
$350001\_04\_2$	10:11:01	10:55:55	2694	6.221	0.511	-0.512	17.8	6.148	625.6	23.2
350 001_06_2	12:01:26	12:47:16	2750	5.924	0.522	-0.508	17.6	6.341	567.4	20.6
350 001_08_2	13:53:04	14:39:20	2776	6.112	0.456	-0.473	17.6	5.696	665.8	24.0
350 001_10_2	15:50:36	16:41:54	3078	5.874	0.449	-0.501	20.3	6.037	850.8	27.6
350 001_12_2	17:48:05	18:29:40	2496	6.307	0.468	-0.509	17.8	5.221	450.2	18.0
350 001_14_2	19:39:19	20:24:40	2721	6.081	0.436	-0.464	19.6	5.273	600.8	22.1
360 001_01_2	6:38:23	7:14:22	2159	6.822	0.466	-0.494	17.7	5.248	275.2	12.7
360 001_03_2	8:24:00	9:10:17	2777	6.111	0.551	-0.529	19.7	6.308	668.6	24.1
360 001_05_2	10:12:04	10:55:16	2592	6.302	0.518	-0.487	19.1	5.890	555.6	21.4
360 001_07_2	12:00:58	12:43:40	2562	6.347	0.550	-0.556	17.2	6.339	533.4	20.8
360 001_09_2	13:54:18	14:49:58	3339	5.759	0.435	-0.487	17.4	6.342	1065.6	31.9
360 001_11_2	15:50:25	16:48:10	3464	5.290	0.423	-0.416	21.3	6.047	1009	29.1
360 001_13_2	17:46:17	18:30:06	2629	6.218	0.445	-0.464	19.2	5.187	543	20.7
370 001_02_2	19:39:07	20:25:55	2815	5.926	0.470	-0.430	17.4	5.363	604.8	21.5

Табела А.2: Снимљени возни циклуси у смеру 2 - апсолутне вредности

шифра циклуса	t <sub>0</sub>	t <sub>f</sub>	$\Delta t$	$\sigma_{apos}$	$\sigma_{\it aneg}$	$\sigma_{mv}$	m <sub>f</sub>	t <sub>stat</sub>	$\delta_{\scriptscriptstyle stat}$
	[h:min:s]	[h:min:s]	[s]	$[m/s^2]$	$[m/s^2]$	[t]	[kg]	[s]	[%]
270 001_02_1	7:31:52	8:17:01	2708	0.374	0.394	1.79	6.985	655.2	24.2
270 001_04_1	9:18:18	10:08:47	3028	0.374	0.362	1.85	7.336	753.4	24.9
270 001_06_1	11:08:34	11:53:45	2710	0.357	0.364	1.25	7.149	646	23.8
270 001_08_1	12:57:07	13:45:50	2923	0.370	0.392	2.02	7.321	729.8	25.0
270 001_10_1	14:54:35	15:42:36	2880	0.405	0.406	1.48	6.674	617.4	21.4
270 001_12_1	16:47:48	17:42:24	3276	0.378	0.393	1.69	6.919	831.8	25.4
270 001_14_1	18:41:42	19:23:35	2512	0.374	0.423	2.25	5.783	507.8	20.2
270 001_16_1	20:34:45	21:13:29	2324	0.374	0.422	1.95	5.451	489.4	21.1
290 001_01_1	7:31:37	8:15:24	2626	0.381	0.357	1.75	7.004	628	23.9
290 001_03_1	9:19:24	10:03:06	2622	0.376	0.357	0.95	6.851	623.4	23.8
290 001_05_1	11:07:54	11:52:41	2688	0.365	0.394	1.04	7.035	619.6	23.1
290 001_07_1	12:58:28	13:47:49	2962	0.363	0.393	1.81	7.920	797	26.9
290 001_09_1	14:54:10	15:47:46	3215	0.389	0.413	2.34	7.237	941	29.3
290 001_11_1	16:49:58	17:43:37	3219	0.399	0.451	2.68	6.677	874.8	27.2
290 001_13_1	18:41:34	19:22:49	2475	0.388	0.448	2.03	6.078	521.2	21.1
310 001_01_1	13:37:11	14:18:53	2515	0.407	0.464	0.39	6.164	580.2	23.1
330 001_01_1	15:00:26	15:40:40	2416	0.403	0.455	1.17	6.418	573	23.7
330 001_03_1	16:34:34	17:13:18	2327	0.395	0.454	0.53	6.013	497.2	21.4
330 001_05_1	18:08:19	18:49:09	2454	0.388	0.452	0.86	6.535	565	23.0
330 001_07_1	19:42:27	20:20:49	2304	0.391	0.420	1.35	6.037	441	19.1
350 001_01_1	7:31:42	8:17:28	2747	0.376	0.360	1.85	7.458	620	22.6
350 001_03_1	9:17:24	10:03:37	2773	0.411	0.362	2.15	6.887	594	21.4
350 001_05_1	11:08:11	11:53:41	2730	0.386	0.392	1.31	7.312	720	26.4
350 001_07_1	12:59:26	13:45:55	2789	0.371	0.413	1.89	8.050	765.6	27.5
350 001_09_1	14:53:37	15:40:34	2818	0.382	0.409	1.12	6.516	684.8	24.3
350 001_11_1	16:49:06	17:37:52	2927	0.395	0.413	1.62	6.667	739.8	25.3
350 001_13_1	18:39:57	19:23:52	2635	0.407	0.434	2.28	6.500	612.8	23.3
350 001_15_1	20:33:00	21:15:55	2574	0.383	0.402	1.14	5.928	629.8	24.5
360 001_02_1	7:32:43	8:23:43	3059	0.384	0.379	2.21	8.008	836.6	27.3
360 001_04_1	9:21:02	10:05:16	2654	0.386	0.387	1.41	7.473	657.2	24.8
360 001_06_1	11:04:59	11:53:54	2935	0.394	0.373	1.30	7.392	742.4	25.3
360 001_08_1	12:57:01	13:44:33	2851	0.379	0.432	1.29	8.148	778.4	27.3
360 001_10_1	14:54:56	15:46:44	3108	0.398	0.398	1.59	7.017	883.8	28.4
360 001_12_1	16:49:24	17:43:02	3217	0.401	0.356	1.87	6.942	802.2	24.9
370 001_01_1	18:41:11	19:26:41	2735	0.408	0.352	1.36	6.098	590.6	21.6
370 001_03_1	20:33:34	21:15:12	2503	0.435	0.381	0.68	6.004	521.4	20.8

Табела А.3: Снимљени возни циклуси у смеру 1 - средња квадратна одступања

шифра циклуса	$t_0$	t <sub>f</sub>	$\Delta t$	$\sigma_{apos}$	$\sigma_{\it aneg}$	$\sigma_{mv}$	$m_f$	t <sub>stat</sub>	$\delta_{\scriptscriptstyle stat}$
	[h:min:s]	[h:min:s]	[s]	$[m/s^2]$	$[m/s^2]$	[t]	[kg]	[s]	[%]
270 001_01_2	6:39:05	7:15:38	2193	0.413	0.351	1.20	5.228	334	15.2
270 001_03_2	8:24:24	9:07:11	2566	0.390	0.377	1.28	5.923	532.2	20.7
270 001_05_2	10:10:58	10:52:50	2512	0.379	0.350	1.09	5.471	396.2	15.8
270 001_07_2	12:01:48	12:45:56	2648	0.389	0.372	1.70	5.976	509.6	19.2
270 001_09_2	13:52:09	14:36:47	2678	0.386	0.413	1.74	5.472	601.4	22.5
270 001_11_2	15:51:15	16:36:56	2740	0.393	0.419	0.97	5.575	624.8	22.8
270 001_13_2	17:47:56	18:32:13	2657	0.387	0.425	1.90	5.424	552.2	20.8
270 001_15_2	19:39:18	20:20:50	2491	0.380	0.418	1.16	4.836	486.2	19.5
$290001\_02\_2$	8:24:36	9:07:03	2546	0.398	0.356	2.07	5.552	494	19.4
290 001_04_2	10:11:47	10:57:35	2747	0.414	0.371	0.84	6.099	673	24.5
290 001_06_2	12:01:28	12:50:11	2924	0.387	0.356	1.58	6.318	728	24.9
290 001_08_2	13:54:52	14:43:09	2897	0.386	0.399	1.88	5.512	642	22.2
290 001_10_2	15:48:53	16:48:36	3583	0.384	0.434	1.24	6.651	1100	30.7
$290001\_12\_2$	17:46:14	18:32:24	2770	0.416	0.478	2.42	6.176	612.2	22.1
290 001_14_2	19:38:47	20:23:10	2662	0.381	0.434	0.80	5.303	605.4	22.7
330 001_02_2	15:46:33	16:26:36	2406	0.405	0.474	1.12	5.150	478.4	19.9
330 001_04_2	17:20:50	18:02:21	2494	0.388	0.460	1.05	5.523	566	22.7
330 001_06_2	18:53:03	19:36:20	2599	0.391	0.414	1.69	5.618	562.4	21.6
330 001_08_2	20:27:38	21:07:21	2386	0.389	0.430	1.32	5.291	459.8	19.3
350 001_02_2	8:24:19	9:08:16	2637	0.407	0.359	1.82	6.136	538.4	20.4
350 001_04_2	10:11:01	10:55:55	2694	0.392	0.370	0.41	6.148	625.6	23.2
350 001_06_2	12:01:26	12:47:16	2750	0.399	0.382	1.31	6.341	567.4	20.6
350 001_08_2	13:53:04	14:39:20	2776	0.388	0.413	1.46	5.696	665.8	24.0
350 001_10_2	15:50:36	16:41:54	3078	0.393	0.433	2.04	6.037	850.8	27.6
350 001_12_2	17:48:05	18:29:40	2496	0.410	0.444	1.60	5.221	450.2	18.0
350 001_14_2	19:39:19	20:24:40	2721	0.386	0.402	1.21	5.273	600.8	22.1
360 001_01_2	6:38:23	7:14:22	2159	0.394	0.370	1.07	5.248	275.2	12.7
360 001_03_2	8:24:00	9:10:17	2777	0.413	0.403	1.63	6.308	668.6	24.1
360 001_05_2	10:12:04	10:55:16	2592	0.395	0.350	0.59	5.890	555.6	21.4
360 001_07_2	12:00:58	12:43:40	2562	0.411	0.391	1.27	6.339	533.4	20.8
360 001_09_2	13:54:18	14:49:58	3339	0.408	0.386	1.40	6.342	1065.6	31.9
360 001_11_2	15:50:25	16:48:10	3464	0.408	0.344	2.22	6.047	1009	29.1
360 001_13_2	17:46:17	18:30:06	2629	0.418	0.385	1.80	5.187	543	20.7
370 001_02_2	19:39:07	20:25:55	2815	0.434	0.357	1.26	5.363	604.8	21.5

Табела А.4: Снимљени возни циклуси у смеру 2 - средња квадратна одступања

шифра циклуса	$\Delta t$	кат 1	v	кат 2	а	m	m.	t	$\delta_{\text{stat}}$
шпфри цпклуси	[6]	Kull I	$\int pos$	Ku1. 2	$\sum_{pos}$	г <sub>у</sub> Г+1		stat	[%]
200.001 12 1	2475	1	6.52	1	0.44	[L] 	<u>[Kg]</u>	[8] 521	
290 001_15_1	2475	1	0.35	1	0.44	20.04	0.00	545	21.1
330 001_03_1 330 001_07_1	2434	1	6.75	2	0.45	10.99	0.33	303 441	25.0 10.1
270.001_07_1	2304	1	0.04	2	0.43	17.90	0.04 5.45	441	17.1
270 001_10_1	2324	1	0.94	2	0.45	19.02	J.4J 6 49	409 572	21.1 22.7
220.001_01_1	2410	1	7.02	2	0.40	16.00	0.42	373	23.7 21.4
220.001_05_1	2327	1	7.00	5 1	0.44	10.51	0.01	497	21.4
2/0001_10_1 250.001_02_1	2000	2	5.75	1	0.45	10.90	0.07	017 504	21.4
270.001_05_1	2775	2	5.95	1	0.51	10.42	0.09	594	21.4
3/0001_01_1 270.001_02_1	2709	2	5.95	1	0.41	17.79	0.10	591 (FF	21.0
270 001_02_1	2708	2	0.27	2	0.49	17.70	0.99	000	24.2
2/0001_00_1 270.001_14_1	2710	2	0.19	2	0.47	18.49	7.15 5 70	040 508	23.8 20.2
2/0001_14_1	2012	2	0.34	2	0.42	10.45	5.70	000	20.2
290.001_01_1	2020	2	0.40	2	0.50	17.91	7.00 6.95	020 602	23.9 22.9
290 001_05_1	2022	2	0.30	2	0.47	10.90	0.05	025	23.0 22.1
290001_05_1 250.001_01_1	2000	2	0.17	2	0.40	19.02	7.04	020 620	23.1
350001_01_1 250.001_05_1	2747	2	0.05	2	0.47	17.97	7.40	020 720	22.0
250.001_05_1 250.001_07_1	2730	2	0.37	2	0.52	19.23	7.31 8.05	720	20.4 27.5
350001_07_1 250.001_00_1	2/89	2	0.32	2	0.55	10.14	8.05 ( 5 9	/00	27.5
350001_09_1 250.001_12_1	2010	2	0.04	2	0.44	20.75	0.52	000	24.3
350001_13_1 2(0.001_08_1	2033	2	0.38	2	0.48	19.43	0.30	013	23.3 27.2
360 001_08_1	2801	2	6.20	2	0.55	18.28	8.15	//8	27.5
310001_01_1	2010	2	6.60	3	0.46	10.5/	0.10 5.02	580	25.1
350 001_15_1	25/4	2	0.00	3	0.44	17.58	5.95	630	24.5
360 001_04_1	2654	2	6.43	3	0.52	17.80	/.4/	637 501	24.8
3/0001_05_1 270.001_12_1	2000	2	0.40 5.20	3 1	0.45	10.79	0.00	521 820	20.8
2/0001_12_1	3270 2010	2	5.50	1	0.42	17.51	0.92	032 075	25.4
290001_11_1 2(0.001_12_1	5219 2017	2	5.44	1	0.45	10.00	0.00	0/0	27.2
270.001_12_1	3217 2028	с 2	5.50	1	0.40	10.04	0.94	802 752	24.9
2/0001_04_1	3020 2015	2	5.04	2	0.49	17.55	7.54	735	24.9
290001_09_1	3213	2	5.08	2	0.42	20.09	7.24	941	29.5
360 001_02_1	3039	3	5.76 5.76	2	0.49	18.50	8.01 7.02	83/	27.5
200001_10_1	2002	3	J./0	2	0.40	19.00	7.02	004 720	20.4
2/0001_08_1	2923	3	5.82 5.00	5	0.49	19.13	7.32	/30	25.0
290001_0/_1	2962	3	5.90	5	0.49	18.34	1.92	191	20.9
350001_11_1 260.001_06_1	2927	3	5.86	3	0.45	17.53	0.07	740 740	25.3
360 001 06 1	2935	3	5.93	3	0.51	18.63	7.39	742	25.3

Табела А.5: Основни параметри снимљених циклуса са редним бројем категорија 1 и 2 за смер 

Табела А.6: основни п	параметри сна	имљених ци	<i>клуса са р</i>	редним б	бројем к	сатегорија .	1 u 2	за с	мер
2									

шифра циклуса	$\Delta t$	кат. 1	$V_{pos}$	кат. 2	$a_{pos}$	$m_{v}$	m <sub>f</sub>	t <sub>stat</sub>	$\delta_{\scriptscriptstyle stat}$
	[s]		[m/s]		$[m/s^2]$	[t]	[kg]	[s]	[%]
270 001_03_2	2566	1	6.33	1	0.50	17.58	5.92	532	20.7
270 001_05_2	2512	1	6.10	1	0.46	19.54	5.47	396	15.8
290 001_02_2	2546	1	6.26	1	0.48	18.18	5.55	494	19.4
330 001_06_2	2599	1	6.40	1	0.46	18.02	5.62	562	21.6
350 001_12_2	2496	1	6.31	1	0.47	17.77	5.22	450	18.0
360 001_05_2	2592	1	6.30	1	0.52	19.13	5.89	556	21.4
360 001_07_2	2562	1	6.35	1	0.55	17.21	6.34	533	20.8
270 001_15_2	2491	1	6.42	2	0.42	20.08	4.84	486	19.5
330 001_02_2	2406	1	6.74	2	0.43	17.38	5.15	478	19.9
330 001_04_2	2494	1	6.74	2	0.45	17.58	5.52	566	22.7
330 001_08_2	2386	1	6.70	2	0.45	17.85	5.29	460	19.3
270 001_01_2	2193	1	6.92	3	0.49	18.05	5.23	334	15.2
360 001_01_2	2159	1	6.82	3	0.47	17.66	5.25	275	12.7
290 001_08_2	2897	2	5.73	1	0.43	18.46	5.51	642	22.2
350 001_10_2	3078	2	5.87	1	0.45	20.33	6.04	851	27.6
270 001_07_2	2648	2	6.05	2	0.51	17.45	5.98	510	19.2
290 001_06_2	2924	2	5.94	2	0.48	17.78	6.32	728	24.9
290 001_12_2	2770	2	6.07	2	0.53	19.05	6.18	612	22.1
350 001_06_2	2750	2	5.92	2	0.52	17.63	6.34	567	20.6
370 001_02_2	2815	2	5.93	2	0.47	17.36	5.36	605	21.5
270 001_09_2	2678	2	6.21	3	0.44	17.72	5.47	601	22.5
270 001_11_2	2740	2	6.09	3	0.43	19.93	5.57	625	22.8
270 001_13_2	2657	2	6.13	3	0.45	18.37	5.42	552	20.8
290 001_04_2	2747	2	6.22	3	0.53	19.52	6.10	673	24.5
290 001_14_2	2662	2	6.26	3	0.44	17.26	5.30	605	22.7
350 001_02_2	2637	2	6.16	3	0.50	18.29	6.14	538	20.4
350 001_04_2	2694	2	6.22	3	0.51	17.80	6.15	626	23.2
350 001_08_2	2776	2	6.11	3	0.46	17.60	5.70	666	24.0
350 001_14_2	2721	2	6.08	3	0.44	19.56	5.27	601	22.1
360 001_03_2	2777	2	6.11	3	0.55	19.75	6.31	669	24.1
360 001_13_2	2629	2	6.22	3	0.45	19.18	5.19	543	20.7
290001_10_2	3583	3	5.26	1	0.46	18.87	6.65	1100	30.7
360 001_11_2	3464	3	5.29	1	0.42	21.28	6.05	1009	29.1
360 001_09_2	3339	3	5.76	3	0.44	17.38	6.34	1066	31.9



Слика А.1: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001\_02\_1, 270 001\_04\_1 и 270 001\_06\_1



Слика А.2: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001\_08\_1, 270 001\_10\_1 и 270 001\_10\_1



Слика А.3: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001\_14\_1, 270 001\_16\_1 и 290 001\_01\_1



Слика А.4: Расподела убрзања и масе возила за возне циклусе са ознакама 290 001\_03\_1, 290 001\_05\_1 и 290 001\_07\_1



Слика А.5: Расподела убрзања и масе возила за возне циклусе са ознакама 290 001\_09\_1, 290 001\_11\_1 и 290 001\_13\_1



Слика А.6: Расподела убрзања и масе возила за возне циклусе са ознакама 310 001\_01\_1, 330 001\_01\_1 и 330 001\_03\_1



Слика А.7: Расподела убрзања и масе возила за возне циклусе са ознакама 330 001\_05\_1, 330 001\_07\_1 и 350 001\_01\_1


Слика А.8: Расподела убрзања и масе возила за возне циклусе са ознакама 350 001\_03\_1, 350 001\_05\_1 и 350 001\_07\_1



Слика А.9: Расподела убрзања и масе возила за возне циклусе са ознакама 350 001\_09\_1, 350 001\_11\_1 и 350 001\_13\_1



Слика А.10: Расподела убрзања и масе возила за возне циклусе са ознакама 350 001\_15\_1, 360 001\_02\_1 и 360 001\_04\_1



Слика А.11: Расподела убрзања и масе возила за возне циклусе са ознакама 360 001\_06\_1, 360 001\_08\_1 и 360 001\_10\_1



Слика А.12: Расподела убрзања и масе возила за возне циклусе са ознакама 360 001\_12\_1, 370 001\_01\_1 и 370 001\_03\_1



Слика А.13: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001\_01\_2, 270 001\_03\_2 и 270 001\_05\_2



Слика А.14: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001\_07\_2, 270 001\_09\_2 и 270 001\_11\_2



Слика А.15: Расподела убрзања и масе возила за возне циклусе са ознакама 270 001\_13\_2, 270 001\_15\_2 и 290 001\_02\_2



Слика А.16: Расподела убрзања и масе возила за возне циклусе са ознакама 290 001\_04\_2, 290 001\_06\_2 и 290 001\_08\_2



Слика А.17: Расподела убрзања и масе возила за возне циклусе са ознакама 290 001\_10\_2, 290 001\_12\_2 и 290 001\_14\_2



Слика А.18: Расподела убрзања и масе возила за возне циклусе са ознакама 330 001\_02\_2, 330 001\_04\_2 и 330 001\_06\_2



Слика А.19: Расподела убрзања и масе возила за возне циклусе са ознакама 330 001\_08\_2, 350 001\_02\_2 и 350 001\_04\_2



Слика А.20: Расподела убрзања и масе возила за возне циклусе са ознакама 350 001\_06\_2, 350 001\_08\_2 и 350 001\_10\_2



Слика А.21: Расподела убрзања и масе возила за возне циклусе са ознакама 350 001\_12\_2, 350 001\_14\_2 и 360 001\_01\_2



Слика А.22: Расподела убрзања и масе возила за возне циклусе са ознакама 360 001\_03\_2, 360 001\_05\_2 и 360 001\_07\_2



Слика А.23: Расподела убрзања и масе возила за возне циклусе са ознакама 360 001\_09\_2, 360 001\_11\_2 и 360 001\_13\_2



Слика А.24: Расподела убрзања и масе возила за возни циклус са ознаком 370 001\_02\_2

# Преглед коришћених скраћеница

# На српском језику

АПС	Алтернативни погонски систем
BHM	Вештачка неуронска мрежа
ДП	Динамичко програмирање
EM	Електрични мотор/машина
ЕХПС	Електрични хибридни погонски систем
КВ	Коленасто вратило
КПС	Конвенционални погонски систем
МСУС	Мотор са унутрашњим сагоревањем
ОЕБС	Организација за европску безбедност и сарадњу
ПЕХПС	Паралелни електрични хибридни погонски систем
ПС	Погонски систем
ПХПС	Паралелни хибридни погонски систем
ПХХПС	Паралелни хидраулични хибридни погонски систем
СУС	Са унутрашњим сагоревањем
СХПС	Серијски хибридни погонски систем
СХХПС	Серијски хидраулични хибридни погонски систем
XM	Хидраулични мотор/машина
ХПС	Хибридни погонски систем
ХХПС	Хидраулични хибридни погонски систем

# На енглеском језику

API	Application Programming Interface
ASCII	American Standard Code for Information Interchange
CAN	Controller Area Network
DRAM	Dynamic Random Access Memory
ECMS	Equivalent Consumption Minimization Strategy
EPA	Environmental Protection Agency
FD	Feedback Delay

FIFO	First In, First Out
FPGA	Field Programmable Gate Arrays
GPS	Global Positioning System
ID	Input Delay
LS	Layer Size
MPC	Model Predictive Control
NARX	Nonlinear AutoRegressive network with eXogenous inputs
NI	National Instruments
NMEA	National Marine Electronics Association
PID	Proportional Integral Derivative
RBC	Rule Based Control
SAE	Society of Automotive Engineers
SOC	State of Charge
ТР	Transport Protocol
VISA	Virtual Instrument Software Architecture

## Биографија

## Лични подаци

Име и презиме:	Марко Н. Китановић
Датум рођења:	29.01.1986.
Место рођења:	Женева, Швајцарска

## Радно искуство

2010. – 2013.	Истраживач-сарадник
	Универзитет у Београду – Машински факултет, Катедра за Моторе
2013 2019.	Асистент
	Универзитет у Београду – Машински факултет, Катедра за моторе

2019. - 2021. Самостални стручнотехнички сарадник, Универзитет у Београду, Катедра за моторе

## Образовање

2005. – 2008.	BSc – Основне академске студије
	Универзитет у Београду – Машински факултет, Катедра за Моторе
	Тема завршног рада: "Анализа идеализованих термодинамичких циклуса
	мотора"
2008 2010.	MSc – Дипломске академске студије
	Универзитет у Београду – Машински факултет, Катедра за моторе

Тема мастер рада: "Истраживање примене поступка турбоекспанзије код мотора СУС"

2010. - 2021. PhD – Докторске академске студије Универзитет у Београду – Машински факултет, Катедра за моторе

#### Вештине

Страни језици	француски, енглески
Стручне вештине	Моделовање радног процеса мотора СУС и хибридних погонских система, Идентификација параметара и калибрација математичких модела
	процеса и феномена, Пројектовање управљачког софтвера за индустријску и
	лабораторијску опрему,
	Пројектовање система аквизиције података, Анализа података,

	Динамичко програмирање.
Остала	Економија, филозофија, праксеологија,
интересовања	Информационе технологије, GNU/Linux, рачунарске мреже,
	Фотографија,
	Астрономија.

## Изјава о ауторству

Име и презиме аутора: Марко Н. Китановић

Број индекса: Д15/10

## Изјављујем

да је докторска дисертација под насловом

#### "Оптимизација функционалних и управљачких параметара хибридног погонског система возила јавног градског превоза"

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени и
- да нисам кршио ауторска права и користио интелектуалну својину других лица.

Потпис аутора

У Београду,

# Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора: Марко Н. Китановић

Број индекса: Д15/10

Студијски програм: Мотори СУС

Наслов рада: Оптимизација функционалних и управљачких параметара хибридног погонског система возила јавног градског превоза

Ментор: Проф. др Слободан Ј. Поповић, ванредни професор

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао ради похрањивања у Дигиталном репозиторијуму Универзитета у Београду.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис аутора

У Београду,

\_\_\_\_\_

## Изјава о коришћењу

Овлашћујем Универзитетску библиотеку "Светозар Марковић" да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

#### "Оптимизација функционалних и управљачких параметара хибридног погонског система возила јавног градског превоза"

која је моје ауторско дело.

Дисертацију са свим прилозима предао сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио.

- 1. Ауторство (СС ВҮ)
- 2. Ауторство некомерцијално (СС ВУ-NС)
- 3. Ауторство некомерцијално без прерада (СС ВУ-NC-ND)
- 4. Ауторство некомерцијално делити под истим условима (СС ВУ-NC-SA)
- 5. Ауторство без прерада (СС ВУ-ND)
- (6. Ауторство делити под истим условима (СС ВУ-SA)

Потпис аутора

У Београду,

1. **Ауторство**. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.

2. **Ауторство – некомерцијално**. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.

3. **Ауторство – некомерцијално – без прерада**. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.

4. **Ауторство – некомерцијално – делити под истим условима**. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.

5. **Ауторство – без прерада**. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.

6. **Ауторство – делити под истим условима**. Дозвољавате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.