



ТЕХНИЧЕСКИ УНИВЕРСИТЕТ – СОФИЯ

Факултет „Компютърни системи и технологии“

Катедра „Компютърни системи“

маг. Стефан Алипиев Цоков

**ОПТИМИЗИРАНЕ НА АРХИТЕКТУРИ НА НЕВРОННИ
МРЕЖИ ЧРЕЗ ЕВОЛЮЦИОННИ АЛГОРИТМИ**

А В Т О Р Е Ф Е Р А Т

на дисертация за придобиване на образователна и научна степен
"ДОКТОР"

Област: 5. Технически науки

Професионално направление: 5.3 Комуникационна и компютърна техника

Научна специалност: „Системи с изкуствен интелект“

Научни ръководители:

проф. д-р инж. Милена Кирилова Лазарова–Мицева

доц. д-р инж. Аделина Пламенова Алексиева–Петрова

СОФИЯ, 2025 г.

Дисертационният труд е обсъден и насочен за защита от Катедрения съвет на катедра „Компютърни системи“ към Факултет „Компютърни системи и технологии“ на ТУ–София на редовно заседание, проведено на 10.11.2025 г.

Публичната защита на дисертационния труд ще се състои на 10.02.2025 г. от 13:00 часа в Конферентната зала на БИЦ на Технически университет – София на открито заседание на научното жури, определено със заповед № ОЖ-5.3.-61/21.11.2025 г. на Ректора на ТУ–София в състав:

1. Проф. д-р Даниела Гоцева – председател
2. Доц. д-р Георги Цочев – научен секретар
3. Проф. д-р Милена Милева-Карова
4. Проф. д-р Тодор Стоилов
5. Проф. д-р Александър Бекярски

Рецензенти:

1. Проф. д-р Тодор Стоилов
2. Доц. д-р Георги Цочев

Материалите по защитата са на разположение на интересуващите се в канцеларията на Факултет „Компютърни системи и технологии“ на ТУ–София, блок №1, кабинет №1443а.

Дисертантът е редовен докторант към катедра „Компютърни системи“ на Факултет „Компютърни системи и технологии“. Изследванията по дисертационната разработка са направени от автора, като някои от тях са подкрепени от научноизследователски проекти.

Автор: маг. Стефан Алипиев Цоков

Заглавие: Оптимизиране на архитектури на невронни мрежи чрез еволюционни алгоритми

Тираж: 30 броя

Отпечатано в ИПК на Технически университет – София

I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност на проблема

Съвременното развитие на изкуствения интелект и машинното обучение поставя на преден план необходимостта от създаване на ефективни и адаптивни модели, които могат да се прилагат в различни области – от автономни системи и роботика до интелигентен анализ на данни и прогнозиране на сложни процеси. Един от основните проблеми в тази област е проектирането на архитектури на невронни мрежи (НМ), което представлява сложен и трудоемък процес, изискващ експертни знания и значителни изчислителни ресурси. Намирането на оптимални архитектури, които да осигуряват висока точност и обобщаваща способност, често се извършва чрез множество експерименти и итерации, което прави задачата изключително времеемка. В този контекст възниква необходимостта от автоматизация и оптимизация на процеса на проектиране на невронно-мрежови архитектури чрез използването на интелигентни метаевристични методи. Приложението на еволюционни стратегии и генетични алгоритми представлява обещаващ подход, който позволява търсене на оптимални решения в големи и сложни пространства от параметри и архитектурни конфигурации. Така се създават възможности за изграждане на ефективни модели без пряка намеса на човека в процеса на настройка и проектиране. Актуалността на изследването в дисертационния труд се обуславя от бързото развитие на дълбокото обучение и нуждата от автоматизирани системи за откриване на оптимални архитектури, особено при задачи с висока сложност и големи обеми данни. Използването на еволюционни алгоритми за автоматична оптимизация на НМ допринася за ускоряване на изследователските и инженерни процеси и позволява прилагането на дълбоки модели в нови домейни, където ръчната настройка е практически невъзможна.

Цел на дисертационния труд, основни задачи и методи за изследване

Целта на дисертационния труд е разработване на еволюционна стратегия за оптимизиране на архитектури на НМ с генетични алгоритми, която да бъде приложена и допълнително модифицирана и валидирана за решаване на конкретни приложни проблеми: управление на автономни агенти; разпознаване на човешки дейности; прогнозиране на замърсяване на въздуха.

Основните задачи за постигане на целта са следните: (1) Литературен обзор на съвременни невронно-мрежови модели за машинно обучение и метаевристични алгоритми за решаване на оптимизационни задачи; (2) Анализ на съществуващи подходи за автоматизиране на проектирането на невронно-мрежови архитектури; (3) Анализ на домейн-специфични невронно-мрежови модели за управление на автономни агенти, разпознаване на човешки дейности, прогнозиране на замърсяване на въздуха; (4) Дизайн на еволюционна стратегия за автоматична оптимизация на архитектури на НМ с определяне на генотипно представяне и кодиране на решения и модифицирани оператори за кръстосване и мутация; (5) Разработване на методология за приложение на еволюционната стратегия за автоматична оптимизация на архитектури на НМ за управление на автономни агенти; (6) Разработване на методология за приложение на еволюционната стратегия за автоматична оптимизация на архитектури на НМ за разпознаване на човешки дейности; (7) Разработване на методология за приложение на еволюционната стратегия за автоматична оптимизация на архитектури на НМ за прогнозиране на замърсяване на въздуха; (8) Провеждане на експерименти с масиви от данни за валидиране на еволюционната стратегия и оценка на ефективността на проектираните модели.

Научните методи, които са използвани са следните: теоретико-аналитични методи за изследване на съществуващи решения и формиране на концептуална рамка за приложението на еволюционни стратегии при автоматизиране на проектирането на архитектури на НМ (анализ на научната литература и добри практики, класификация на съществуващи методи и подходи и домейн-специфични НМ модели, сравнителен анализ на съществуващи архитектури за обогатеното извличане на знание); методи на моделиране и формализиране на еволюционни стратегии и генетични алгоритми (концептуално моделиране, формално описание на генетични алгоритми и генетични оператори, математическо моделиране на еволюционни стратегии и генетични алгоритми за конкретни приложни задачи); емпирични и експериментални методи за проверка на хипотезите и оценка на ефективността на еволюираните модели (експерименти с реални масиви данни, оценка на модели с различни метрики, статистически методи за потвърждение на значимостта на резултатите и за проверка на основни и частни хипотези).

Научна новост

Предложен е генетичен алгоритъм за оптимизация на архитектурата на НМ, който постепенно увеличава сложността решенията при нужда, използва модифициран оператор за кръстосване за решения с вариращи дължини и адаптивна мутация с три стратегии за промени в архитектурите на НМ. Предложен е генетичен алгоритъм за еволюционно базиран дизайн на конволюционни НМ за разпознаване на човешка дейност с използване на модифицирано кръстосване за решения с различна дължина и адаптивна мутация с три равновероятни стратегии за модифициране на слой, добавяне на слой и премахване на слой от архитектурата на НМ. Предложен е метод за автоматична оптимизация на архитектурата на конволюционни НМ за разпознаване на човешки дейности, при който еволюционния процес започва от прости архитектури, които постепенно могат да бъдат усложнявани чрез добавянето на нови слоеве. Предложен е хибриден дълбок пространствено-темпорален модел базиран на конволюционна НМ и LSTM мрежа за прогнозиране на замърсяването на въздуха с автоматичен подбор на входни променливи и оптимизация на хиперпараметрите на модела. Предложена е хибридна стратегия за запълване на липсващи стойности във времеви редове, която е приложена за обучение на хибридният дълбок пространствено-темпорален модел за прогнозиране на замърсяване на въздуха. Предложен е подход за включване на еволюирани архитектури за хибриден дълбок пространствено-темпорален модел за прогнозиране на замърсяването на въздуха в различни ансамбли, състоящи се от модели с еднакви архитектури и модели с различни архитектури. Предложена е стратегия за подбор на входни променливи при прогнозиране на замърсяването на въздух с хибриден дълбок пространствено-темпорален модел. Предложен е подход за включване на пространствена информация при прогнозиране на замърсяването на въздух с хибриден дълбок пространствено-темпорален модел.

Практическа приложимост

Интегрирането на предложените решения е насочено към индустриални и научни приложения, които са силно ресурсоемки и трудни за формализиране и при които обемът на данните и сложността на задачите правят ръчната настройка на НМ модели практически невъзможна, като позволяват съществено да се намали зависимостта от човешка експертиза и да се съкрати времето за разработване на високоефективни НМ архитектури, с което автоматично да се създават модели, приложими в реални системи за управление, анализ и прогнозиране, в това число в интелигентни транспортни системи, индустриална автоматизация и системи за мониторинг на околната среда, за които необходимостта от модели с висока обобщаваща способност и адаптивност е особено значима, а автоматизираните подходи за проектиране на архитектури могат да имат пряко въздействие върху качеството и надеждността на решенията.

Апробация

Резултатите от дисертационния труд са разглеждани, обсъждани и публикувани в Списание „Computer and Communication Engineering”; Девета международна научна конференция „Computer Science’2020”, Велинград, България, 18-21 октомври, 2020; Сборник научни трудове на Технически университет–София; 22^{ра} Международна научна конференция „CompSysTech’2021“, 18–19 юни 2021, Русе, България; Международно научно списание Indian Journal of Computer Science and Engineering; Международна научна конференция „ICTTE’2020“, 4–6 ноември 2020, Ямбол, България; Международно научно списание MDPI Sustainability; Научен семинар на докторанти във Факултет по Компютърни системи и технологии на 12 юни 2020 и 25 юни 2021.

Публикации

Основни постижения и резултати от дисертационния труд са публикувани в 8 научни статии, от които 1 самостоятелна. Научните статии са представени и публикувани в национални и международни конференции и международни реферирани и индексирани издания.

Структура и обем на дисертационния труд

Дисертационният труд е в обем от 217 страници, като включва увод, пет глави за решаване на формулираните основни задачи, списък на основните приноси, списък на публикациите по дисертацията и използвана литература. Цитирани са общо 206 литературни източници, всичките на латиница. Работата включва общо 39 фигури и 42 таблици. Номерата на фигурите, таблиците и използваната литература в автореферата съответстват на тези в дисертационния труд.

II. СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

ГЛАВА 1. НЕВРОННО-МРЕЖОВИ МОДЕЛИ ЗА МАШИННО ОБУЧЕНИЕ

Първа глава поставя теоретичната основа на изследването като разглежда същността на невронните мрежи, подходи за формулиране и решаване на оптимизационни задачи, както и принципите на еволюционното изчисление и еволюционните алгоритми.

1.1. Невронни мрежи – същност, изкуствен неврон, архитектури

Изкуствените невронни мрежи (НМ) се състоят от множество взаимосвързани изчислителни единици (неврони), които обработват информация паралелно. Всеки неврон приема входни сигнали, претегля ги чрез синаптични тегла, добавя прагова константа и прилага активационна функция (стъпкова, сигмоидна, ReLU, Softmax). НМ са организирани в слоеве – входен, скрити и изходен. Архитектурата играе важна роля в определянето на поведението на системата и зависи от спецификата на задачата, като се разграничават два основни типа: еднопосочни и рекурентни. Обучението на НМ се състои в минимизиране на функция на загуба чрез итеративна актуализация на параметрите на мрежата посредством обратно разпространение на грешката.

Дълбоките НМ са особено подходящи за решаване на комплексни задачи, като два популярни подхода представляват конволюционните НМ (CNN) и Long Short-Term Memory (LSTM). CNN са способни на автоматично извличане на релевантни характеристики, чрез конволюция на входния сигнал с филтри. LSTM представлява рекурентна НМ, използваща паметов блок, позволяващ на системата да моделира дългосрочни зависимости във входните данни.

1.2. Оптимизационна задача

Оптимизационната задача цели намиране на най-доброто решение чрез минимизиране или максимизиране на целева функция при зададени ограничения. В зависимост от вида на променливите и функцията, задачите могат да бъдат линейни, нелинейни, непрекъснати, дискретни, конвексни или многокритериални.

Традиционните методи за оптимизация са предимно числени и се делят на градиентни (използват производни) и безградиентни. Основните градиентни подходи са методът на най-стръмното спускане, Нютоновият метод, квазинютоновите методи и стохастичното градиентно спускане (SGD), широко използвано при обучение на НМ.

1.3. Метаевристични алгоритми за решаване на оптимизационни задачи

Градиентните методи са ефективни при гладки, конвексни и диференцируеми функции, но често се затрудняват при сложни, нелинейни и мултимодални задачи. В такива случаи се използват алтернативни метаевристични методи, които търсят висококачествени решения без гаранция за глобален оптимум, но с добра практическа ефективност. Тези методи са генерални и третираат задачата като „черна кутия“, като включват в себе си стохастични компоненти за избягване на засядане в локални оптимуми и подобряване на изследването на пространството, балансирайки между глобално изследване и локално прецизиране.

Метаевристичните подходи се делят на:

- методи по траектории (метод „изкачване на хълм“, Табу търсене, симулирано закаляване), които работят с едно решение и са склонни към засядане в локални оптимуми, но са бързи;
- методи с популации, които работят с множество решения – еволюционни алгоритми и алгоритми с рояци (PSO, ACO). Те са по-подходящи за глобално търсене и оптимизация при многомерни пространства.

1.4. Еволюционни изчисления

Еволюционните алгоритми (ЕА) са вдъхновени от биологичната еволюция, като работят с популация от решения и чрез цикъл от оценяване, селекция и възпроизвеждане чрез вариация, итеративно подобряват качеството на решенията. Основни компоненти на тези алгоритми са:

- представяне на решението – най-често се ползват вектори, пермутации, графи и дървета.
- популация – създаване на начална популация и определяне на размера на популацията.
- селекция на родители и оцелели – насочва процеса на търсене към по-обещаващи региони от пространството и осигурява сходимост. Селекцията на родители определя индивидите,

които ще участват в генерирането на потомство. Селекцията на оцелели се прилага след създаването на потомство и определя кои индивиди ще съставят следващото поколение.

- оператори за вариация (мутация и кръстосване) – представляват механизми за въвеждане на разнообразие в популацията. Мутацията въвежда случайна промяна в един родител, докато кръстосването комбинира информация от двама или повече родители, подпомагайки разпространението на полезни градивни блокове в популацията.

Популярни представители са: генетични алгоритми, еволюционни стратегии, генетично програмиране и еволюционно програмиране.

1.5. Изводи към първа глава

В резултат на направения литературен обзор на невронно-мрежовите модели за машинно обучение, както и на метаевристичните алгоритми за решаване на оптимизационни задачи могат да бъдат направени следните по-важни изводи:

- НМ са вдъхновени от биологичната нервна система и са мощен инструмент за обработка на сложни данни и моделиране на зависимости;
- Дълбоките архитектури значително разширяват възможностите на машинното обучение, но проектирането им е трудно, изисква експертиза и много ресурси;
- Оптимизирането на архитектури на НМ е сложен оптимизационен проблем, за който класическите методи често са неефективни;
- Метаевристичните алгоритми, особено еволюционните стратегии и генетичните алгоритми, са подходящи за такива задачи, защото извършват глобално търсене и не изискват аналитично описание на целевата функция;
- Теоремата „No Free Lunch“ подчертава, че няма универсален оптимизационен метод – изборът на алгоритъм трябва да се съобрази с конкретната задача.

Изводите подкрепят хипотезата, че оптимални архитектури на НМ могат да се намират чрез метаевристични алгоритми, което е основа за разглежданите в дисертационния труд приложения за управление на автономни агенти, разпознаване на дейности и прогнозиране на замърсяване на въздух.

ГЛАВА 2. ОПТИМИЗИРАНЕ НА АРХИТЕКТУРИ НА НЕВРОННИ МРЕЖИ С ЕВОЛЮЦИОННИ АЛГОРИТМИ

Втора глава представя предложен подобрен генетичен алгоритъм за автоматично проектиране на архитектури на невронни мрежи, използващ модифициран оператор за кръстосване за решения с варираща дължина и адаптивна мутация. Предложеният метод е сравнен с други съвременни методи за оптимизиране на архитектури на невронни мрежи.

2.1. Същност на оптимизирането на архитектури на невронни мрежи

Архитектурата на НМ оказва силно влияние върху представянето на модела, като различни задачи поставят различни изисквания върху дълбочината и организирането мрежата. Изборът на подходяща архитектура обикновено се състои в настройването на голям брой хиперпараметри като брой слоеве, техният тип и параметри, коефициенти за регуляризация, скорост на обучение и други, което често прави ръчната оптимизация трудна, бавна и неефективна.

Голяма част от съвременните методи за оптимизиране на невронни архитектури имат за цел да улеснят изследователите, като намалят зависимостта от специализирани знания, чрез автоматизиране на оптимизационния процес. За подобряване на ефективността при изследване на големи пространства от архитектури, тези подходи често използват еволюционни алгоритми, байесовата оптимизация и обучение с утвърждение.

2.2. Методи за автоматично оптимизиране на архитектури на невронни мрежи

С оглед на значителното време, необходимо за оценка на моделите, автоматизираните методи за оптимизация на архитектури често използват различни техники за ускоряване на процеса като съкратено обучение за малък брой епохи, частично обучение върху подмножество от данните, споделяне на тежести, обучение на по-малки модели, както и прогностични модели за преждевременно прекратяване на обучението на некачествени архитектури.

Класически методи за оптимизация на хиперпараметри като grid search и случайно търсене имат своите недостатъци. Grid search страда от експоненциално нарастване на комбинациите,

докато случайното търсене не се възползва от натрупания опит по време на оптимизационния процес за адаптивно ориентиране на търсенето. За преодоляване на тези ограничения могат да се използват различни адаптивни методи, като обучение с утвърждение и метаевристики.

Редица проведени изследвания върху задачи с изображения показват, че обучението с утвърждение е способно автоматично да генерира конкурентни архитектури.

Различни метаевристични алгоритми също са приложени за оптимизиране на архитектурите на CNN, сред които с популярността и доброто си представяне се открояват PSO и еволюционните алгоритми.

2.3. Оптимизация на архитектури на невронни мрежи с генетичен алгоритъм с модифициран оператор за кръстосване и адаптивна мутация

В дисертацията е предложен генетичен алгоритъм за автоматизиране на оптимизацията и дизайна на архитектури на НМ, който използва модифициран оператор за кръстосване за решения с варираща дължина и адаптивна мутация. Предложеният метод дава възможност за поетапно нарастване на сложността на решенията в хода на еволюционния процес.

Решенията са с варираща дължина и представляват поредица от компоненти (слоеве или популации от неврони), характеризиращи се с набор от параметри, позволявайки оптимизирането както на дълбочината на архитектурата, така и на отделните характеристики на всеки компонент. Началната популация се формира от малки случайно генерирани функционални архитектури.

Кръстосването се извършва на ниво компоненти, т.е. кръстосват се компоненти между двата родителя. Тъй като решенията са с различна дължина, се използва модифициран едноточков оператор за кръстосване, при който първо се избира точка на кръстосване в по-дългото решение, а за по-късото решение точката се изчислява така, че относителната позиция да съответства на тази в по-дългото.

Вероятността за извършване на кръстосване се определя по формулата:

$$p = 1 - \frac{|l_1 - l_2|}{\max(l_1, l_2) - 1} \quad (2.1)$$

където l_1 и l_2 са дължините (броя компоненти) на двете решения.

По този начин вероятността за кръстосване зависи от това колко подобни по дълбочина са двете решения, за които се прилага кръстосването.

След кръстосването за новополучените дъщерни решения се прилага адаптивна мутация с определена вероятност, която е голяма в началото на еволюционния процес и постепенно намалява в неговия ход до определена минимална стойност.

Предложени са три типа мутации:

- Модифициране на компонент: стойността на един от параметрите на случайно избран компонент се променя с друга валидна стойност;
- Добавяне на компонент: добавя се нов случайно генериран компонент на определено място в решението;
- Премахване на компонент: избира се един от съществуващите компоненти и се премахва.


2.4. Сравнителен анализ на предложения метод за оптимизиране на архитектури на невронни мрежи

В таблица 2.1 и на фиг. 2.2 е представено сравнение между предложения метод за оптимизиране на архитектури на невронни мрежи и стандартни Neural Architecture Search (NAS) техники, стандартни генетични алгоритми със статично кръстосване и ръчна (експертна) оптимизация по няколко ключови критерия. Като направения анализ показва следните ключови предимства на предложения метод за оптимизация на архитектури на НМ:

- много висока гъвкавост на архитектурата благодарение на добавяне/премахване на компоненти;
- минимален проху гар, защото не се използват релаксации;
- адаптивност чрез прогресивна комплексност и динамична мутация;
- по-ниска изчислителна цена от някои NAS методи, макар не толкова ниска като при ръчната оптимизация;
- висока автоматизация в сравнение с ръчния подход.

Таблица 2.1. Сравнителен анализ на предложения метод за оптимизиране на архитектури на невронни мрежи

Критерий	Предложен ГА	Диференцируем NAS	Стандартен ГА	Ръчна оптимизация
Поддържане на променлива дълбочина	да (динамична чрез add/remove)	ограничена (фиксиран суперграф)	ограничена (фиксиран размер на хромозома)	не
Стратегия за комплексност	прогресивна (от прости към сложни)	обикновено фиксирана	не	изцяло ръчна
Необходимост от релаксация	не	да (softmax релаксации)	не	не
Риск от prou gap	нисък	висок	нисък	няма
Адаптивна мутация	да	не	обикновено не	не
Оператори Add/Remove	да	не	не	не
Мултицелеви оптимизации	да (лесно интегрируеми)	възможно (но сложно)	възможно (с модификации)	изключително трудно
Интерпретируемост	висока	средна	висока	висока
Изчислителна цена	средна (еволюционен подход)	висока (непрекъснато обучение)	средна	много висока



Фигура 2.2. Радар диаграма за сравнение на предложението за оптимизиране на архитектури на невронни мрежи с генетичен алгоритъм с модифициран оператор за кръстосване и адаптивна мутация с други методи

2.5. Изводи към втора глава

По-важните изводи и резултати във втора глава могат да бъдат обобщени както следва:

- Използването на подходяща архитектура на НМ за решаване на съответна задача е от критична важност за успешното създаване на полезен, надежден и ефективен невронно-мрежов модел, но изборът и дизайнът на НМ архитектура не е лесна задача. Въпреки, че съществуват множество решения за автоматизиране на проектиране на архитектури на НМ, които преодоляват

проблемите на ръчната оптимизация, всеки от съществуващите подходи има различни проблеми, недостатъци и ограничения.

- Предложен е генетичен алгоритъм за оптимизация на архитектурата на НМ, който постепенно увеличава сложността на решенията при нужда, използва модифициран оператор за кръстосване за решения с вариращи дължини и адаптивна мутация с три стратегии за промени в архитектурите на НМ.

Основните предимства на предложения метод за оптимизация на архитектурата на НМ с използване на генетичен алгоритъм могат да бъдат обобщени както следва:

1. Гъвкава поддръжка на променлива дълбочина: методът позволява динамична промяна на архитектурната дълбочина чрез оператори за добавяне и премахване на компоненти, комбинирани с модифицирано кръстосване като по този начин се осигурява едновременно оптимизация на броя слоеве и техните параметри.
2. Постепенно увеличаване на сложността: алгоритъмът реализира стратегия за прогресивно усложняване на архитектурите, при която оптимизацията започва с прости модели и увеличава тяхната комплексност само при наличие на необходимост.
3. Ниска чувствителност към релаксации и приближения: за разлика от диференцируемите NAS методи, при които дискретните архитектурни избори се заменят с континуирани вероятности чрез релаксация (например с softmax), предложеният подход оперира в дискретно пространство като елиминира риска от несъответствия между оптимизираната архитектура и финалния дискретен модел („rough gap“).
4. Адаптивна стратегия за мутация: вероятността за мутация се регулира динамично по време на еволюцията – висока в началните поколения за насърчаване на разнообразие и постепенно намаляваща към края на оптимизацията за прецизно донагласяне на параметрите. Това осигурява балансирано съотношение между изследване (exploration) и експлоатация (exploitation).
5. Контролирано структурно модифициране: включването на три вида мутации (модифициране на параметри, добавяне и премахване на компоненти) позволява ефективно изследване на архитектурното пространство като едновременно се поддържа структурна валидност на решенията и се избягва генерирането на некоректни архитектури.
6. Подходящ за мултицелеви оптимизации: алгоритъмът лесно се разширява за оптимизация по множество критерии (например точност, брой параметри, латентност, енергийна ефективност) без необходимост от промяна на основния механизъм на еволюционното търсене.
7. Интерпретируемост и проследимост на еволюционния процес: използваните оператори са интуитивни и лесно интерпретируеми, което позволява анализ на еволюционната траектория и идентифициране на структурни мотиви, довели до оптимални решения.

ГЛАВА 3. ЕВОЛЮИРАНЕ НА НЕРВНА СИСТЕМА ЗА УПРАВЛЕНИЕ НА АВТОНОМНИ АГЕНТИ

Трета глава представя предложен в дисертационния труд метод за еволюиране на изкуствена нервна система за управление на автономни агенти, използваща индиректно кодиране и генетичен алгоритъм.

3.1. Същност на еволюционната роботика

Еволюционната роботика използва еволюционни алгоритми за автоматично проектиране на системи за управление на автономни агенти. В сравнение с традиционните подходи за дизайн на контролери, които обикновено изискват значителни предварителни познания за средата и взаимодействията с нея, еволюционните методи освен, че облекчават работата на изследователите и инженерите, но и предоставят възможност за откриване на нови и неочаквани поведения.

Основното предизвикателство пред еволюционната роботика, възпрепятстващо по-широкото ѝ практическо приложение, е еволюирането на сложни поведения. В литературата са предложени множество решения на този проблем като модулност, постепенна еволюция, използване на по-сложни невронни модели, неограничена (отворена) еволюция и индиректно кодиране.

3.2. Невронни модели за еволюиране на автономни агенти

Разгледани са три основни невронни модела, използвани при еволюирането на контролни системи за автономни агенти:

- Неврон на McCulloch и Pitts – прагов модел с бинарен (или сигмоиден) изход. Използва се широко в областта на еволюционната роботика, заради своята простота.

- Непрекъснатовремени рекурентни невронни мрежи (CTRNN) – биологично по-реалистичен модел, позволяващ моделиране на по-сложно поведение на невроните, чрез включване на времева динамика.
- Спайкови невронни мрежи – биологично реалистичен модел, моделиращ активността на невроните чрез спайкове (потенциали за действие) и позволяващ възникването на сложна динамика.

Невронни модели за еволюиране на автономни агенти според метода на кодиране

Различават се два основни подхода за кодиране на генетичната информация и трансформация от генотип към фенотип:

- Директно кодиране – генотипът съдържа пълното описание на НМ, като преобразуването между генотип и фенотип е еднозначно. Подходът е по-популярен заради концептуалната си простота, но страда от слаба мащабируемост. Популярен представител е NEAT.
- Индиректно кодиране – генотипът съдържа само ключови характеристики на НМ, чрез които се разгръща цялата мрежа. Подходът предоставя по-компактно представяне на решенията, но често води до формиране на мрежи с регулярна структура. По-известни представители са: HyperNEAT, клетъчно кодиране, модели с генетични регулаторни мрежи и Analog Genetic Encoding.

Невронни модели за еволюиране на автономни агенти според задаване на фитнес функция

Изборът на подходяща фитнес функция е критичен, тъй като чрез нея експериментаторът може неволно да наложи ограничения, които да възпрепятстват еволюционния процес и да предотвратят постигането на желаното поведение. Според начина на задаване на фитнес функцията НМ за управление на автономни агенти могат да бъдат разделени в две основни категории:

- модели с изрично зададена фитнес функция - оценката се получава чрез предварително зададени критерии. Основни видове фитнес функции са: базирани на обучаващи данни, обобщени, поведенчески, приспособени, инкрементални и конкурентни;
- модели без изрично зададена фитнес функция - често се използват при отворената еволюция. Основават се на новост, енергийни механизми и други стратегии.

3.3. Моделиране на изкуствена нервна система за автономни агенти с индиректно кодиране и генетичен алгоритъм

Базирайки се на наблюдения върху биологичното развитие на нервните системи в дисертационния труд е предложен модел за развитие на изкуствена нервна система за управление на автономни агенти. Развитието на системата е структурирано в три последователни фази:

- Фаза 1: миграция на неврони;
- Фаза 2: формиране на връзки;
- Фаза 3: адаптация на връзките в зависимост от активността на мрежата по време на жизнения цикъл на агента.

В предложения модел за развитие НМ за управление на автономни агенти са разположени в двумерна равнина и се кодират индиректно като поредица от невронни подпопулации. Подпопулациите се позиционират една след друга по хоризонталната ос: най-напред се разполагат невроните от първата подпопулация, вдясно от тях – невроните от следващата, и т.н.

Геном

Геномът е с променлива дължина (минимална дължина - 2) и представлява поредица от невронни подпопулации – първата е входна, а последната е изходна.

Всяка междинна подпопулация се характеризира чрез следните параметри:

- Брой неврони.
- Лично пространство на невроните (personalspace) – определя минималната допустима дистанция между два неврона от подпопулацията, така че те да не се припокриват.
- Координати на върхове на четириъгълник – определят площта на четириъгълник, в рамките на която могат да бъдат разполагани невроните от подпопулацията.
- Максимална дължина на аксона – определя най-голямото разстояние, при което невроните от подпопулацията могат да образуват връзки с други неврони.
- Праг на активация и скорост на обучение – използват се за промяна на теглата в зависимост от активността на НМ.


Параметрите са нормализирани в интервала $[0, 1]$, а при сглобяване се мащабират спрямо броя неврони.

Поставяне и преместване на неврони в подпопулация


Невроните се разполагат така, че личните им пространства да не се припокриват. Входните и изходните неврони се подреждат вертикално, останалите – в четириъгълна форма, като първо се позиционират неврони във върховете, а всеки следващ – в центъра на подпопулацията. При припокриване се прилага отблъскваща сила F (фиг. 3.2), насочена по правата, свързваща двата неврона (фиг. 3.1) и с големина определена от разстоянието d между тях, докато припокриването се отстрани или се достигне лимит от стъпки:

$$|F| = 2 * \text{personal space} - d \quad (3.3)$$

Невроните във върховете са фиксирани, а излезлите извън границите се връщат чрез огледално отражение.



Фигура 3.1. Неврон n_2 действа на неврон n_1 с избухваща сила, тъй като n_1 е навлязъл в личното му пространство.



Фигура 3.2. Неврон n_1 е навлязъл в личните пространства на неврони n_2 и n_3 , които започват да му действат с избухващи сили F_{21} и F_{31} съответно. Крайното преместване се определя от сбора на тези сили – F_{net} .

Свързване на невроните

След позиционирането се определя конективността на мрежата: всеки неврон се свързва с всички неврони вдясно от него, намиращи се в обсега на максималната дължина на аксона му, като началните тегла се задават като $1/d$ според разстоянието d . След това се премахват излишни компоненти, които не допринасят към изходния сигнал или не приемат входна информация.

Използване на активността на НМ за обучение на параметри

Теглата на връзките се адаптират по време на живота на агента според активността на НМ чрез пресинаптичното правило, актуализиращо връзки само при активен пресинаптичен неврон — увеличават се, ако постсинаптичният е активен, и намаляват в противен случай:

$$w_{ij}^t = w_{ij}^{t-1} + \eta \Delta w_{ij}, 0 < \eta \leq 1 \quad (3.4)$$


където Δw_{ij} е +1 или -1 в зависимост от това дали постсинаптичният неврон е активен или не, а η е скоростта на обучение. Теглата имат стойности между -1 и 1.

3.4. Експериментално тестване на модел за развитие на изкуствена нервна система за управление на автономни агенти

Предложеният модел е тестван експериментално чрез симулация на автономен агент в изкуствен свят.

Симулиран свят

Изкуственият свят представлява двумерна квадратна арена, дискретизирана на клетки (квадрати), изцяло оградена от стени. В рамките на арената се разполагат обекти от два типа: храна и отрова. На фиг. 3.13 е показан примерен симулиран свят. Агентът е визуализиран като окръжност, ориентацията му е обозначена със стрелка, храните са представени чрез триъгълници, а отровите – чрез ромбове. Запълнените клетки маркират стените.



Фигура 3.13. Примерен свят с размер 20×20 с 5 храни и 5 отрови.

Агентът притежава ориентация, енергия и сензорна информация за обекта пред себе си, както и за собственото си енергийно състояние. Способен е да се движи напред или да се завърта в двете посоки. Взаимодействията с различните обекти могат да променят енергията на агента – храната я увеличава, отровата и стените я намаляват. Освен това всяко действие и времева единица също консумират енергия. Целта е агентът да се научи да различава полезни от вредни обекти, като избягва стените и отровата и консумира храната.

Генетичен алгоритъм

Използван е генетичен алгоритъм за оптимизиране на броя и параметрите на подпопулациите в НМ. Експериментите са проведени с популация от 100 индивида и 200 поколения, с турнирна селекция ($t = 2$) и елитизъм. Входният слой съдържа 5 неврона (различните типове обекти, включително празна клетка, и енергията), а изходният – 3 неврона (трите възможни действия). Към входа и изхода е добавен шум ($\mu = 0$ и $\sigma = 0.05$). Невроните използват сигмоидна активация и не се допускат рекурентни връзки. Експериментът е повторен три пъти.

Началната популация съдържа случайно генерирани НМ с входна и изходна подпопулация и 0–10 междинни подпопулации (1–10 неврона всяка).

Кръстосване и мутация

Вероятността за кръстосване (минимум 0.05) се определя чрез уравнение (2.1), като l_1 и l_2 представляват броя на подпопулациите в двата родителя.

Мутацията започва с вероятност 0.9 и намалява до 0.2, със стъпка от 0.01 на поколение.

Използват се три типа мутации:

- Модифициране на подпопулация: Един от параметрите на произволно избрана подпопулация се променя. За върховете на четириъгълника се генерира нова координата. Броят неврони се увеличава или намалява с 1. Всички останали параметри се мутират чрез добавяне на шум с нормално разпределение ($\mu = 0$, $\sigma = 0.01$).
- Добавяне на междинна подпопулация: Вмъква се нова случайно генерирана междинна подпопулация на произволна позиция в решението.
- Премахване на междинна подпопулация: Случайно избрана междинна подпопулация се премахва.

Вероятността за модифициране е 50%, а добавянето и премахването са равновероятни.

Фитнес функция

Агентът стартира от произволна позиция и с произволна ориентация в среда 20×20 със 100 храни и 100 отрови на случайни позиции. Началната енергия е 1000 единици, а енергийната граница за „здравословно“ състояние е 500. Агентът изпълнява действия до изчерпване на наличната си енергия или до достигане на предварително определен максимален брой времеви стъпки (1500). Енергията намалява за всяка времева стъпка (–1), при извършване на действие (–10), при сблъсък със стена (–200) и при консумирането на отрова (–400). При консумирането на храна енергията се увеличава с 400 единици.

Фитнес функция е проста и измерва колко дълго агентът поддържа енергията си над зададения праг. Всеки индивид се оценява чрез 10 независими изпълнения върху случайно инициализирани светове, като тези 10 среди са еднакви за всички индивиди:


$$\text{fitness} = \frac{1}{n} \left(\sum_{i=1}^n \text{fit}_i \right) - \alpha \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\text{fit}_i - \overline{\text{fit}})^2} \quad (3.5)$$

където n е броят изпълнения, а $\alpha = 0.1$. Целта е да се селектират не само индивиди с високо средно представяне, но и такива с устойчиво поведение между отделните изпълнения.


На индивиди с некоректно дефинирани подпопулации им се присвоя фитнес 0.

Експериментални резултати


На фиг. 3.14, 3.15 и 3.16 са показани сглобените НМ на най-добрите индивиди след премахването на излишните части. Входните неврони са оцветени в синьо, а изходните — в оранжево. Подредбата на входните неврони отдолу нагоре съответства на следната информация: празна клетка, стена, храна, отрова и вътрешна енергия. Аналогично, изходните неврони отдолу нагоре отговарят за действията: завъртане по часовниковата стрелка, завъртане обратно на часовниковата стрелка и движение напред.



Фигура 3.14. НМ получена от най-добрия индивид от последното поколение на първото изпълнение на експеримента.



Фигура 3.15. НМ получена от най-добрия индивид от последното поколение на второто изпълнение на експеримента.



Фигура 3.16. НМ получена от най-добрия индивид от последното поколение на третото изпълнение на експеримента.

При две от изпълненията (фиг. 3.14 и фиг. 3.15) алгоритъмът еволюира сходни прости архитектури, които използват само входовете за храна, стена и празна клетка. В третото изпълнение (фиг. 3.16) най-добре представящата се НМ използва единствено информацията за наличие на отрова, като игнорира останалите входове. Нито една от еволюираните мрежи не използва входа, свързан с вътрешната енергия на агента.

Агентите, управлявани от най-добрите мрежи от първите две изпълнения, демонстрират подобни поведенчески стратегии: събират храна и избягват стени, но не реагират на отрова. Агентът от третото изпълнение успява да избягва отровата, но не показва реакция към други видове обекти.

Фитнесът както на най-добрите индивиди, така и на цялата популацията се увеличава в хода на еволюционния процес, като агентите бързо усвояват стратегии за избягване на опасности и събиране на храна, поддържайки енергията си над зададената граница до края на оценяването.

3.5. Изводи към трета глава

По-важните изводи и резултати, получени в трета глава на дисертационния труд могат да бъдат обобщени както следва:

- Областта на еволюиране на НМ за управление на автономни агенти претърпява значително развитие от началото си през 80-те и 90-те години, но въпреки това развитие някои проблеми остават нерешени, като например получаването на сложни поведения: повечето еволюирани поведения са сравнително прости като избягване на препятствия, следване на източник на сигнал (например светлина или звук) и други.
- Редица стратегии са предложени за преодоляването на тези ограничения и проблеми като постепенна еволюция, генеративни кодирання, използване на по-правдоподобен невронен модел позволяващ по-богата динамика, както и използване на неограничена еволюция без изрично зададена фитнес функция.
- За да може еволюционната роботика да се развива допълнително трябва да покаже, че е способна да произвежда сложни поведения, които могат да намерят приложение в реални ситуации.
- В дисертационния труд е предложена биологично вдъхновена индиректна схема на кодиране за еволюиране на НМ за управление на автономни агенти, при която НМ се развиват и впоследствие по време на живота на агента се дооформят от неговите взаимодействия със средата.
- Вземането предвид на взаимодействията на агента с околната среда в хода на неговото развитие може да улесни еволюционния процес чрез получаване на агенти, способни да се адаптират към специфичната среда. Гъвкавостта на генома от своя страна може да улесни еволюцията на по-сложни системи.
- Експерименталното тестване на предложения метод върху симулация на изкуствен свят показва, че с използване на проста имплицитна фитнес функция успешно се еволюират агенти способни да разграничават различни обекти.
- Разработената индиректна схема за кодиране на НМ за управление на автономни агенти има възможност да генерира разнообразни и комплексни архитектури със сравнително малък на брой параметри спрямо други възможни подходи за еволюиране на нервна система за управление на автономни агенти.

ГЛАВА 4. ЕВОЛЮЦИОННО БАЗИРАН ДИЗАЙН НА КОНВОЛЮЦИОННА НЕВРОННА МРЕЖА ЗА РАЗПОЗНАВАНЕ НА ЧОВЕШКА ДЕЙНОСТ

Четвърта глава представя предложен в дисертационното изследване еволюционно базиран метод за дизайн на конволюционна невронна мрежа за разпознаване на човешка дейност.

4.1. Същност на задачата за автоматизирано разпознаване на човешка дейност

Системите за автоматизирано разпознаване на човешки дейности обикновено се състоят от набор от сензори, информацията от които се обработва от алгоритми за машинно обучение, които класифицират отделни дейности, като например ходене, хранене, тичане и други.

Такива системи могат да използват различни типове сензори за събиране на данни: видео камери, носими сензори, сензори вградени в средата. Всеки със своите предимства и недостатъци от гледна точка на точност, ниво на инвазивност и количество контекстуална информация.

Разпознаването на човешки дейности намира редица приложения в различни области: умни домове, здравеопазване и подпомагане на възрастни хора и други.

Традиционните подходи за автоматизирано разпознаване на човешки дейности обикновено включват ръчно извличане на характеристики от суровия сигнал.

Популярните традиционни алгоритми са: методът на опорните вектори, скритите марковски модели, методът на К-най-близките съседи, дърветата на решенията, наивните байесови класификатори и методът на условните случайни полета. През последните години методите за дълбоко обучение придобиват особена популярност в разпознаването на човешки дейности поради способността им да улавят значително по-сложни зависимости и закономерности в данните.

4.2. Конволюционни невронни мрежи за разпознаване на човешка дейност

Конволюционните НМ се използват често за решаване на задачи, свързани с разпознаване на дейности, поради способността си автоматично да извличат релевантни характеристики директно от суровите входни данни. Основен техен недостатък е необходимостта от значителен обем аотирани данни за обучение. CNN често се представят по-успешно спрямо редица класически модели.

Представянето на конволюционните НМ зависи силно от архитектурата на модела, като определянето ѝ е сложна задача, тъй като включва избор на множество хиперпараметри: брой и типове слоеве (конволюционни, пулуващи, напълно свързани), тяхната свързаност, както и параметрите на всеки от тях (брой филтри, размер и стъпка на филтрите, размер и тип на pooling операциите, брой неврони и др.). Поради големия брой възможни конфигурации, в практиката често се разчита на ръчна оптимизация, изискваща значителни специализирани знания от страна на експериментатора. Следователно разработването на ефективни автоматизирани методи за оптимизиране на архитектурата на конволюционни НМ е от ключово значение за научни изследвания и практически приложения в областта на разпознаването на човешка дейност.

4.3. Еволюционно базиран дизайн на конволюционни невронни мрежи за разпознаване на човешка дейност

За оптимизация на архитектурата на конволюционна НМ за разпознаване на човешка дейност в дисертационния труд се предлага използване на генетичен алгоритъм със стандартната алгоритмична последователност.

Представяне на решение

Решенията представляват архитектури на конволюционни НМ с променлива дължина и се състоят от две основни части – конволюционна и напълно свързана. Всяка от тези части може да съдържа k на брой слоеве, като всеки слой се характеризира със съответните му параметри.

Формално решението може да бъде представено във вида $[C,D]$:

$$\begin{aligned} C &= [c_1, c_2, c_3, \dots, c_n], \quad D = [d_1, d_2, d_3, \dots, d_m], \\ c_i &= [hc_1, hc_2, hc_3, \dots, hc_k], \quad d_i = [hd_1, hd_2, hd_3, \dots, hd_l], \end{aligned} \quad (4.1)$$

където C обозначава конволюционната част, D – напълно свързаната част, n е броят конволюционни слоеве, m – броят напълно-свързани слоеве, hc са параметрите на конволюционните слоеве, а hd – параметрите на напълно свързаните слоеве.

Начална популация

Началната популация се формира от случайно генерирани архитектури с минимална допустима големина – един конволюционен и един напълно свързан слой. По този начин еволюционният алгоритъм започва с популация от относително прости мрежи, които постепенно нарастват по сложност в хода на еволюционния процес.

Фитнес функция

За ускоряване на оптимизацията, обучението на архитектурите по време на еволюцията се извършва за малък брой епохи (5). В рамките на еволюционния процес моделите се обучават върху обучаващо множество, а качеството им се оценява върху отделно валидационно множество. За фитнес стойност се използва класификационната точност.

Кръстосване

За оператор на кръстосване се използва модифицирано едноточково кръстосване, адаптирано за решения с променлива дължина. Операцията по кръстосване се прилага върху конволюционната или напълно свързаната част, с вероятност определена по уравнение (2.1) и минимална вероятност от 0.05, като l_1 и l_2 обозначават брой слоеве в избраната част в двете решения.

Мутация

След кръстосване новосъздадените решения могат да бъде мутирани с динамична вероятност, започваща от 0.8 и намаляваща с 0.05 за всяко поколение до достигане на минималната стойност от 0.2.

Прилага се една от три възможни равновероятни мутации:

- Модифициране на слой: променя се стойността на един от хиперпараметрите на случайно избран слой, чрез замяна с друга валидна стойност;
- Добавяне на слой: в решението се вмъква нов, случайно генериран слой на произволна позиция;
- Премахване на слой: изтрива се случайно избран съществуващ слой.

Избор на най-добра архитектура и пълно обучение

След оптимизацията се избира най-добрата архитектура от последното поколение, която се обучава 10 независими пъти за 100 епохи върху обединението от обучаващото и валидационното множество данни и се оценява върху тестовото множество.

4.4. Експериментални резултати за оценка на еволюционно базиран дизайн на конволюционни невронни мрежи за разпознаване на човешка дейност

В изследването се използват сравнително малък размер на популацията (20) и ограничен брой поколения (50).

За избора на родители при оператора за кръстосване се прилага турнирен подбор с турнирен размер 2. В еволюционната процедура не е включен механизъм за елитизъм. Максималният брой конволюционни слоеве е ограничен до 10, а максималният брой напълно свързани слоеве – до 5.

Таблица 4.1 представя допустимите стойности за всеки хиперпараметър, характеризиращ определен слой.

Таблица 4.1. Възможни стойности за всеки от оптимизираните хиперпараметри

<i>Конволюционна част</i>	
Брой филтри	[16, 32, 64, 128, 256]
Размер на филтъра	[2, 3, 4, 5, 6, 7, 8, 9]
Включване на pooling слой	[True, False]
<i>Напълно свързана част</i>	
Брой неврони	[100, 250, 500, 750, 1000]
Използване на dropout	[True, False]
Dropout p	[0.1, 0.2, 0.3, 0.4, 0.5]

Всички слоеве използват ReLU за активационна функция. Стъпката на конволюционните слоеве е 1, а допълването е „valid“. Използва се max-pooling с фиксиран размер (2), стъпка (2) и валидно допълване. Последният слой представлява softmax слой. Обучението се извършва чрез минимизиране на функцията на кръстосана ентропия, използвайки алгоритъма Adam.

За оценяване на най-добрите модели, получени от еволюционния процес, се използват следните метрики: точност (accuracy), прецизност (precision), пълнота (recall), специфичност (specificity) и F_1 оценка (F_1 score).

Използвани масиви от данни и обработка

Предложеният еволюционен метод е експериментално валидиран върху три общодостъпни масива от данни за разпознаване на човешка дейност: WISDM Actitracker, Smartphone-Based Recognition of Human Activities and Postural Transitions Dataset и PAMAP2. Всеки масив е разделен на обучаващо, валидационно и тестово множество. Експериментите са повторени 10 пъти.

Експериментални резултати за масива WISDM Actitracker

Оптималните архитектури обикновено съдържат 4–5 конволюционни слоя, често с max-pooling и 2–3 напълно свързани слоя, обикновено с размер на слоевете 500 или 750 неврона. Dropout се използва в около половината случаи (най-често $p = 0.3$).

Получените резултати по F_1 и точност (таблица 4.3) показват конкурентно представяне, сравнимо със съвременни ръчно проектирани модели (таблица 4.4).


Матрицата на объркване (фиг. 4.3) показва отлично разпознаване на Sitting (без грешки) и много висока точност за Walking, Jogging, и Standing ($F_1 \geq 0.95$). Най-трудни за класификация са Upstairs и Downstairs, с F_1 около 0.8, поради сходство между тях. Средната F_1 оценка е 0.9194 ± 0.0711 .

Таблица 4.3. Средни стойности спрямо класовете на F_1 score и точност за най-добрата архитектура от всяко експериментално изпълнение върху масива WISDM Actitracker.

Изпълнение	Средна F_1 оценка $\pm \sigma$	Средна точност $\pm \sigma$
1	0.9126 $\pm$ 0.0889	0.9780 $\pm$ 0.0164
2	0.9027 $\pm$ 0.0954	0.9746 $\pm$ 0.0180
3	0.8724 $\pm$ 0.0989	0.9687 $\pm$ 0.0187
4	0.9123 $\pm$ 0.0918	0.9778 $\pm$ 0.0169
5	0.9010 $\pm$ 0.0821	0.9762 $\pm$ 0.0149
6	0.9194 $\pm$ 0.0779	0.9790 $\pm$ 0.0149
7	0.8891 $\pm$ 0.0933	0.9734 $\pm$ 0.0173
8	0.8999 $\pm$ 0.0935	0.9755 $\pm$ 0.0170
9	0.8905 $\pm$ 0.0909	0.9746 $\pm$ 0.0157
10	0.8836 $\pm$ 0.1116	0.9702 $\pm$ 0.0218

Таблица 4.4. Сравнение с други методи използващи масива от данни WISDM Actitracker.

Модел	Точност (%)
DBN	98.23
CNN	96.88
CNN	98.2
CNN (предложен метод)	96.87 – 97.90



Фигура 4.3. Средна матрица на обръкване спрямо 10 обучаващи повторения за най-добрата архитектура от експериментално изпълнение №6 върху масива WISDM Actitracker.

Експериментални резултати за масива Smartphone-Based Recognition of Human Activities and Postural Transitions Dataset

Повечето оптимални архитектури имат 4–5 конволюционни слоя, обикновено последвани от max-pooling. Обикновено се използва един напълно свързан слой, често с 500 или 750 неврони, като в около половината случаи е приложен dropout (най-често $p = 0.1$).

Резултатите (таблица 4.7) показват, че еволюираните архитектури, демонстрират висока ефективност, превъзхождайки значително някои съвременни дълбоки архитектури, използващи същия масив от данни (таблица 4.8).


Таблица 4.7. Средни F_1 score и точност спрямо класовете на най-добрата архитектура от всяко експериментално изпълнение върху Smartphone-Based Recognition of Human Activities and Postural Transitions Dataset.

Изпълнение	Средна F_1 оценка $\pm \sigma$	Средна точност $\pm \sigma$
1	0.9307 $\pm$ 0.0894	0.9751 $\pm$ 0.0332
2	0.9296 $\pm$ 0.0882	0.9748 $\pm$ 0.0328
3	0.9208 $\pm$ 0.0995	0.9717 $\pm$ 0.0365
4	0.9243 $\pm$ 0.0972	0.9728 $\pm$ 0.0362
5	0.9225 $\pm$ 0.1003	0.9722 $\pm$ 0.0373
6	0.9231 $\pm$ 0.0974	0.9725 $\pm$ 0.0357
7	0.9223 $\pm$ 0.1062	0.9719 $\pm$ 0.0393
8	0.9293 $\pm$ 0.0913	0.9746 $\pm$ 0.0340
9	0.9225 $\pm$ 0.1010	0.9721 $\pm$ 0.0375
10	0.9334 $\pm$ 0.0841	0.9761 $\pm$ 0.0313

Таблица 4.8. Сравнение с други методи използващи масива от данни Smartphone-Based Recognition of Human Activities and Postural Transitions Dataset.

Модел	Точност (%)
2D CNN+SVM	94.49
1D CNN	94.79
1D CNN (предложен метод)	97.17 – 97.61

Моделът разпознава laying, walking, walking_downstairs и walking_upstairs (фиг. 4.5) с много висока точност ($F_1 > 0.97$). Най-чести грешки има при разграничаване между sitting и standing (F_1 малко над 0.8). Средната F_1 оценка е 0.9334 ± 0.0841 .



Фигура 4.5. Средна стойност спрямо 10 обучаващи повторения на най-добрата архитектура от експериментално изпълнение №10 върху Smartphone-Based Recognition of Human Activities and Postural Transitions Dataset.


Експериментални резултати върху масива PAMAP2

Най-добрите архитектури обикновено включват 3–6 конволюционни слоя, понякога с max-pooling и 2 или 4 напълно свързани слоя, най-често със 100 неврони и използване на dropout (най-често $p = 0.4$ и 0.5). Таблица 4.11 показва добрата ефективност на тези архитектури.

Таблица 4.11. Средни стойности спрямо класовете за F_1 оценка и точност на най-добрата архитектура от всяко експериментално изпълнение върху масива PAMAP2.

Изпълнение	Средна F_1 оценка $\pm \sigma$	Средна точност $\pm \sigma$
1	0.7184 ± 0.1836	0.9404 ± 0.0285
2	0.6829 ± 0.1693	0.9310 ± 0.0266
3	0.6867 ± 0.2293	0.9289 ± 0.0441
4	0.6536 ± 0.2261	0.9267 ± 0.0310
5	0.7387 ± 0.1999	0.9432 ± 0.0345
6	0.6965 ± 0.2113	0.9369 ± 0.0338
7	0.7117 ± 0.2295	0.9363 ± 0.0412
8	0.7008 ± 0.1885	0.9344 ± 0.0346
9	0.6985 ± 0.2362	0.9345 ± 0.0404
10	0.6819 ± 0.1798	0.9272 ± 0.0356

Моделът има най-големи затруднения при разпознаването на клас lying (фиг. 4.6), като често го бърка със sitting или standing. Също така обърква ascending stairs с descending stairs и vacuum cleaning с ironing. Най-добре се класифицира walking, а ironing – сравнително точно. Средната F_1 оценка е 0.7387 ± 0.1999 .



Фигура 4.6. Средна матрица на объркване спрямо 10 обучаващи повторения на най-добрата архитектура от експериментално изпълнение №5 върху масива PAMAP2.

Допълнително експериментално тестване

Проведени са два допълнителни експеримента върху масива WISDM Actitracker:

- Случайно търсене: получените средни резултати ($F_1 = 0.8838 \pm 0.0254$, Accuracy = 0.9706 ± 0.0061) са по-ниски и по-нестабилни в сравнение с основния еволюционен експеримент.
- Еволюционно търсене, базирано единствено на мутация: резултатите ($F_1 = 0.8861 \pm 0.0243$, Accuracy = 0.9715 ± 0.0062) са близки, но по-ниски и с по-големи вариации между изпълненията спрямо пълния еволюционен подход с кръстосване. Това показва, че

използването на модифицираната стратегия за кръстосване допринася за по-стабилен и надежден оптимизационен процес.

4.5. Изводи към четвърта глава

По-важните изводи и резултати, получени в четвърта глава на дисертационния труд могат да бъдат обобщени както следва:

- Разпознаването на човешки дейности продължава да бъде трудна задача поради множество проблеми при проектирането на модели за автоматизирано разпознаване: една и съща дейност може да бъде изпълнена по различни начини от различни хора; различни дейности могат да бъдат много подобни от гледна точка на активациите на сензорите.
- Повечето научни изследвания за решаване на тази задача са свързани с разпознаването на малък брой сравнително прости дейности, извършвани от единствен потребител. Освен това, използваните множества данни често са небалансирани, което намалява точността при разпознаването на някои дейности.
- Представянето на системата за разпознаване на дейности силно зависи от използваните характеристики. Някои дълбоки НМ, като конволюционните НМ, предоставят възможност за автоматично извличане на подходящи характеристики и показват по-добри експериментални резултати.
- Използване на неподходяща конволюционна мрежа за съответната задача може да доведе до значително влошаване на цялостното представяне на модела. Ръчното проектиране на архитектури е бавен и трудоемък процес, който обикновено изисква значителни специализирани знания.
- Автоматизирането на търсенето на подходящи архитектури може значително да улесни процеса на оптимизация и да позволи по-широкото използване на дълбоки мрежи, както от научната общност, така и от ИТ индустрията. В научни изследвания са предложени редица различни варианти за автоматично оптимизиране на конволюционни архитектури за разпознаването на човешки дейности, в това число използване на обучение с утвърждение, както и различни метаевристични подходи.
- В дисертационния труд е предложен метод за автоматична оптимизация на архитектурата на конволюционни НМ за разпознаване на човешки дейности, при който еволюционния процес започва от прости архитектури, които постепенно могат да бъдат усложнявани чрез добавянето на нови слоеве.
- Предложеният генетичен алгоритъм за еволюционно базиран дизайн на конволюционни НМ за разпознаване на човешка дейност използва модифицирано кръстосване за решения с различна дължина и адаптивна мутация с три равновероятни стратегии за модифициране на слой, добавяне на слой и премахване на слой от архитектурата на НМ.
- Резултатите от експерименталната оценка на еволюционно базирания дизайн на конволюционни НМ за разпознаване на човешка дейност за масива WISDM Actitracker са близки до представянето на други дълбоки архитектури, използващи същия масив от данни, докато за масива Smartphone-Based Recognition of Human Activities and Postural Transitions Dataset резултатите са значително по-добри в сравнение с други дълбоки архитектури.
- Предложеният еволюционно базиран подход показва по-постоянни резултати от случайното търсене и еволюционното търсене само с мутация, като по този начин осигурява надежден подход за дизайн на конволюционни НМ за разпознаване на човешки дейности.

ГЛАВА 5. ПРОСТРАНСТВЕНО-ТЕМПОРАЛЕН НЕВРОНАЛЕН МОДЕЛ ЗА ПРОГНОЗИРАНЕ НА ЗАМЪРСЯВАНЕ НА ВЪЗДУХА

Пета глава представя предложен в дисертационното изследване хибриден пространствено-темпорален дълбок модел базиран на конволюционна НМ и LSTM мрежа за прогнозиране на замърсяването на въздуха с автоматичен подбор на входни променливи и оптимизация на хиперпараметрите на модела. Предложена е също и хибридна стратегия за попълване на липсващите стойности в използваните множества данни за обучение на модела.

5.1. Същност на задачата за прогнозиране на замърсяване на въздуха

Замърсяването на въздуха представлява наличие в атмосферата на определени вещества в концентрации, достатъчни да предизвикат неблагоприятно въздействие върху растителния и животинския свят, както и върху околната среда. Замърсителите се характеризират с разнообразен

химичен състав, свойства и произход. Сред тях се открояват праховите части с аеродинамичен размер под $2.5\ \mu\text{m}$ (PM_{2.5}), които са свързани с респираторни, сърдечно-съдови заболявания и преждевременна смърт.

Прогнозирането на качеството на въздуха предоставя ключова информация за предприемане на своевременни мерки както от държавни институции, така и от отделни граждани.

Съвременните модели за прогнозиране на замърсяването на въздуха могат да бъдат разделени на два основни типа:

- Детерминистични модели - симулират атмосферни процеси, но са сложни и тежки.
- Статистически модели - основават се на анализ на зависимости в наличните данни, по-прости, по-леки и по-лесни за имплементиране.

Рекурентните НМ са ефективни за моделиране на времеви зависимости, но страдат от проблема с изчезващия градиент. LSTM мрежите преодоляват този недостатък чрез използване на паметови клетки, което им позволява да уловят дългосрочни зависимости и ги прави широко използвани в прогнозиране на замърсяването на въздуха. Хибридните модели, комбиниращи CNN и LSTM, придобиват все по-голяма популярност в моделирането на качеството на въздуха, като често водят до по-висока точност спрямо чисти LSTM архитектури.

За успешното представяне на един статистически модел за прогнозиране на замърсяването на въздуха трябва да бъдат решени някои важни проблеми:

- Липсващи стойности - преди модела да бъде обучен е необходимо запълване на липсващите данни, като изборът на подходящ метод зависи от тяхното количество и особености.
- Подбор на входни променливи - селектиране на релевантни характеристики и изключване на излишни такива е определящо за доброто представяне на модела.
- Включване на пространствена информация - включването на данни от съседни райони има възможност значително да подобри представянето на модела.
- Оптимизация на модела - автоматизиране на оптимизацията може значително да подобри и улесни процеса в сравнение с често използвания подход „проба–грешка“.

5.2. Методи за прогнозиране на замърсяване на въздуха

Запълване на липсващи стойности

Линейната интерполация като метод за запълване на липсващи стойности се представя добре при кратки интервали с липсващи стойности, но с нарастване на интервала ефективността ѝ спада, като при по-дълги интервали по-точни са хибридните методи.

Подбор на входни променливи

Използването на различни подходи за намиране на оптимално подмножество от входни променливи, води до подобряване на представянето на моделите за прогнозиране на замърсяването на въздуха.

Оптимизиране на хиперпараметрите на модела

Ръчното определяне на хиперпараметрите на модела често е неефективно, поради което множество изследователи предпочитат автоматизирани подходи за оптимизация като grid search, случайно търсене и генетични алгоритми, които водят до по-добри модели.

Пространствено-темпорални модели

Вземането предвид на пространствена информация от съседни области, обикновено чрез хибридни структури, значително подобрява получените прогнози от моделите.

5.3. Пространствено-темпорален невронален модел за прогнозиране на замърсяване на въздуха

В дисертационния труд е предложен хибриден пространствено-темпорален дълбок модел (CNN–LSTM) за прогнозиране на замърсяването на въздуха с автоматичен подбор на входни променливи, оптимизация на хиперпараметрите и хибридна стратегия за попълване на липсващи данни.

За експериментална оценка е използван общодостъпен масив – Beijing Multi-Site Air-Quality Data Dataset, съдържащ данни за замърсители и метеорологични променливи от 12 станции за периода 2013–2017 г.

Предварителна обработка на данните

Запълване на липсващи стойности

При анализа на данните е установено наличие на големи интервали с липсващи данни, поради което е предложен хибриден метод за запълване на липсващи стойности:

- малки интервали (до 20 последователни липсващи стойности) с липсващи данни се запълват чрез линейна интерполация;
- големи интервали (над 20) се запълват чрез изчисляване на средна стойност между последната налична стойност и усреднена стойност за съответния час от съответния ден и месец, като се използват данни от другите години, за които има налични валидни измервания.

Нормализация и разделяне на масива на части

Данните са нормализирани с Robust Scaler, част от библиотеката Scikit-learn за Python и разделени на обучаващо, валидационно и тестово множество по години за гарантиране на адекватно отразяване на сезонни и годишни вариации.

Подбор на входни характеристики

В дисертационния труд се предлага стратегия за подбор на входни променливи чрез генериране на 50 случайни входни конфигурации и оптимизиране на модел за всяка една от тях чрез случайно търсене с по 50 генерирани случайни решения. Всяка конфигурация се обучава за 5 епохи върху обучаващото множество и се оценява върху валидационното множество чрез MAE. Най-добрата конфигурация, получена чрез случайното търсене, включва следните променливи: $PM_{2.5}$, PM_{10} , SO_2 , налягане, точка на оросяване, количество валеж, посока на вятъра и скорост на вятъра.

Пространствено-темпорален модел

Предложеният пространствено-темпорален модел представлява хибридна архитектура, комбинираща 2D CNN и LSTM мрежа. Моделът се състои от две основни компоненти:

- конволюционна част, която автоматично извлича пространствени характеристики;
- LSTM част, ползваща извлечените характеристики за моделиране на времеви зависимости.

Моделът е предназначен за прогнозиране на концентрацията на $PM_{2.5}$ за следващата времева стъпка (в конкретния случай – следващия час) за дадена станция, като отчита информация и от околните станции, позволявайки моделиране на пространствено-темпорални зависимости.

Входните данни за конволюционната част представляват изображения с размер 25×25 пиксела, центрирани върху станцията за която се прави прогноза и кодиращи:

- стойността на определена променлива за конкретен момент от време както за целевата станция, така и за съседните станции;
- относителните позиции на станциите в пространството.

Стойностите на определена променлива за всички станции, включени в изображението, се представят като окръжности с център, местоположението на станцията в изображението, и радиус r , пропорционален на стойността на променливата за съответната станция:

$$r = r_{max} * x_{var} \quad (5.2)$$

$$r_{max} = \frac{s_p}{N_{st}} \quad (5.3)$$


където x_{var} е нормализираната стойност на съответната променлива, s_p е броя пиксели на една страна от изображението (25), а N_{st} е броят станции влизащи в околността на целевата станция.

На всички пиксели, попадащи в дадената окръжност, се присвоява стойност 1; при припокриване на окръжности стойностите на пикселите се сумират. В последствие, получените стойности за всички пиксели се нормализират. На фиг. 5.2 е представено примерно входно изображение.

Оптимизиране на архитектурата

В много изследвания архитектурите на моделите за прогнозиране на замърсяването на въздуха се оптимизират чрез подход „проба и грешка“, поради което в настоящата дисертация се предлага автоматизиран подход за оптимизация на архитектурите на НМ, както и на други хиперпараметри, чрез генетичен алгоритъм с модифициран оператор за кръстосване, позволяващ работа с решения с различна дължина. За отделните станции се оптимизират отделни модели. Качеството (фитнес)

на конкретно решение се оценява чрез MAE, като моделът се обучава 5 епохи върху обучаващото множество данни и се тества върху валидационното множество.



Фигура 5.2. Примерно входно изображение с размера на околността 0.6 за PM_{2.5} на 29 юни 2015 в 0 часа за целева станция Dongsi и околни близки станции.

Представяне на решения

Решенията се състоят от три компонента: конволюционна, LSTM и глобална част (таблица 5.2). Конволюционната и LSTM части се състоят от определен брой слоеве, всеки от които се характеризира с дадени параметри.

Таблица 5.2. Възможни стойности на оптимизираните хиперпараметри.

	Хиперпараметър	Възможни стойности
Конволюционна част	Брой филтри	[16, 32, 64, 128, 256]
	Размер на филтъра	[2, 3, 4, 5, 6, 7, 8, 9]
	Включване на max-pooling слой	[True, False]
LSTM част	Брой LSTM елементи	[25, 50, 100, 150, 200, 250]
	Използване на dropout	[True, False]
	Dropout p	[0.1, 0.2, 0.3, 0.4, 0.5]
Глобална част	Размер на околността (v_{norm})	[0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1]
	Размер прозорец назад във времето	[1, 2, 3, 4, 5, 6, 7, 8]

Глобалната част съдържа два параметъра:

- Нормализиран размер на околност (v_{norm}) - определящ големината на околността (v) около целевата станция за прогнозиране:

$$v = v_{norm} * 2\max(dx, dy) \quad (5.4)$$

$$dx = \max(x_{center} - x_{min}, x_{max} - x_{center}) \quad (5.5)$$

$$dy = \max(y_{center} - y_{min}, y_{max} - y_{center}) \quad (5.6)$$

където v_{norm} заема възможни стойности от 0 до 1, x_{center} и y_{center} са координатите на целевата станция, а x_{min} , x_{max} , y_{min} и y_{max} са съответно минималните и максималните координати по x и y измежду всички 12 станции. Географската дължина се използва за x , а ширината – за y , без допълнителни трансформации.

Околността представлява квадрат, центриран върху станцията, като в изображението се включват всички станции, чиито координати попадат в този квадрат. По-малки стойности на v_{norm} включват само най-близките станции, докато по-големи стойности позволяват включването на по-отдалечени станции.

- Размер на прозореца за наблюдение назад във времето – определя броя на предходните времеви стъпки (в случая часове), които се използват като входни данни за модела.

Избор и обучение на най-добра архитектура

След приключване на еволюционната процедура най-добрата архитектура от последната генерация се избира за финално обучение върху обединеното обучаващо и валидационно

множество за 100 епохи, като тестването и оценката се извършват върху тестовото множество. За надеждна оценка на представянето всяко обучение се повтаря 10 независими пъти.

Метрики за оценка

За оценка на представянето на най-добрите архитектури се ползват следните стандартни метрики: средна абсолютна грешка (MAE), корен от средната квадратична грешка (RMSE) и коефициент на детерминация (R^2).

5.4. Експериментално тестване и резултати

Експериментална постановка

Моделите са реализирани с Keras и обучени с Adam, като за активационна функция е използвана ReLU. Конволюционните слоеве са дефинирани със стъпка (stride) (1, 1) и valid padding, а max-pooling слоевете са с размер (2, 2), стъпка (2, 2) и valid padding. Еволюцията е извършена с популация 20 за 50 поколения с елитизъм със стойност 2, а максималният брой конволюционни и LSTM слоеве е съответно 10 и 5.

Експериментите са проведени върху три предварително подбрани станции – Dongsi, Wanliu и Changping, като за всяка станция е оптимизиран отделен модел, а оптимизацията е повторена три пъти.

В допълнение към основния експеримент са проведени допълнителни експерименти върху станция Wanliu: (1) включване на вече обучените модели в различни ансамбли; (2) валидиране на предложената хибридна стратегия за запълване на липсващи стойности; (3) валидиране на различни компоненти от предложения пространствено-темпорален модел.

Резултати от основен експеримент

Получените резултати (таблици 5.3, 5.4 и 5.5) показват, че за всяка станция са намерени подходящи архитектури, които демонстрират стабилно и добро представяне, като най-добри резултати са постигнати за станция Wanliu.

Направеното сравнение с резултати от други изследвания, използващи същия масив данни за прогнозиране на $PM_{2.5}$ за трите станции (таблици 5.6, 5.7 и 5.8) показва, че в повечето случаи предложеният в дисертационния труд модел демонстрира съизмерими резултати с повечето други съвременни модели, като за станция Wanliu представянето е съпоставимо с някои други дълбоки модели.

Таблица 5.3. Резултати за метрики за оценка на най-добрата архитектура за всяко експериментално изпълнение за станция Dongsi.

Изпълнение	MAE	RMSE	R^2
1	17.866 ± 0.672	33.274 ± 1.351	0.853 ± 0.012
2	19.128 ± 0.863	31.326 ± 2.637	0.869 ± 0.023
3	18.446 ± 0.797	30.207 ± 2.076	0.878 ± 0.017

Таблица 5.4. Резултати за метрики за оценка на най-добрата архитектура за всяко експериментално изпълнение за станция Wanliu.

Изпълнение	MAE	RMSE	R^2
1	15.370 ± 0.586	25.165 ± 1.652	0.904 ± 0.013
2	16.753 ± 0.384	26.446 ± 0.707	0.894 ± 0.006
3	15.675 ± 0.375	24.714 ± 0.751	0.908 ± 0.006

Таблица 5.5. Резултати за метрики за оценка на най-добрата архитектура за всяко експериментално изпълнение за станция Changping.

Изпълнение	MAE	RMSE	R^2
1	15.673 ± 0.374	29.429 ± 1.155	0.869 ± 0.010
2	16.085 ± 0.384	31.382 ± 1.502	0.850 ± 0.014
3	15.161 ± 0.199	27.394 ± 1.165	0.886 ± 0.010

Таблица 5.6. Сравнение с други модели за станция Dongsі и масива данни Beijing Multi-Site Air-Quality Data Dataset за прогнозиране на PM_{2.5}.

Модел	MAE	RMSE
FBProphet	15.1	20.5
ARIMA	14.1	19.8
LSTM	13.2	21.3
CNN	16.1	22.0
CNN-LSTM	9.653	17.706

Таблица 5.7. Сравнение с други модели за станция Wanliu и масива данни Beijing Multi-Site Air-Quality Data Dataset за прогнозиране на PM_{2.5}.

Модел	MAE	RMSE
FBProphet	14.7	19.6
ARIMA	14.2	19.3
LSTM	15.9	23.9
CNN	13.9	23.4
CNN-LSTM	8.486	14.951

Таблица 5.8. Сравнение с други модели за станция Changping и масива данни Beijing Multi-Site Air-Quality Data Dataset за прогнозиране на PM_{2.5}.

Модел	MAE	RMSE
FBProphet	13.2	18.9
ARIMA	13.3	19.2
LSTM	12.7	18.8
CNN	14.0	20.2
CNN-LSTM	8.873	15.710

Анализът на оптимизираните архитектури за трите станции (особено при станция Wanliu) показва, че най-добрите модели почти винаги използват максимален размер на околността, което означава включване на всички станции. Моделите използват голям брой стъпки назад във времето (7–8) като входна информация. Получените резултати показват ползата от включването на пространствена информация от възможно повече околни станции, както и използването на възможно най-много историческа информация. Повечето оптимизирани модели съдържат един конволюционен слой, обикновено с малък брой филтри и малък размер на филтъра, като около половината случаи включват max-pooling слой. След конволюционната част често се използват един или два LSTM слоя, като в около половината случаи е приложена dropout регуляризация със сравнително малки стойности на параметъра p (0.1, 0.2 и 0.3).


На фигури 5.3, 5.4 и 5.5 са показани прогнозираната спрямо реалната стойност за трите станции за целия тестови период. Получените резултати показват, че моделите се справят добре с прогнозата на общите тенденции, като известни трудности се наблюдават при прогнозиране на пикови концентрации, особено когато пиковите са значително високи, което се вижда най-ясно за станция Changping (фиг. 5.5).

Формиране на ансамбли от тренираните модели


Проведен е допълнителен експеримент с образуване на ансамбли от вече обучени модели от основния експеримент чрез две стратегии:

- ансамбъл от модели с една и съща архитектура – включва десетте независими обучения на най-добрата архитектура, получена от определено изпълнение на еволюционната оптимизация;


- ансамбъл с модели с различни архитектури – включва k най-добри модела от пълните обучения за всяко експериментално изпълнение.



Фигура 5.3. Реална стойност и осреднената прогнозирана стойност за тестовия период за станция Dongsì от експериментално изпълнение №3.



Фигура 5.4. Реална стойност и осреднената прогнозирана стойност за тестовия период за станция Wanliu от експериментално изпълнение №3.



Фигура 5.5. Реална стойност и осреднената прогнозирана стойност за тестовия период за станция Changping от експериментално изпълнение №3.

Резултатите от ансамблите с модели с еднаква архитектура са представени в таблици 5.12, 5.13 и 5.14, докато резултатите от ансамблите с различни архитектури са показани в таблици 5.15, 5.16 и 5.17. Анализът показва, че и двете стратегии подобряват резултатите спрямо отделните модели.

В почти всички случаи ансамбълът от k най-добри модели дава по-добро представяне, като оптималните стойности на k са: Dongsì – 3, Wanliu – 8, Changping – 2.

В сравнение с резултати от други изследвания ансамблите за станции Dongsì и Changping демонстрират подобна MAE, но по-висока RMSE, най-вероятно заради почасовите, а не дневни прогнози. За станция Wanliu предложените ансамбли превъзхождат резултатите от литературата.

Таблица 5.12. Резултати за станция Dongsi на ансамбъла съставен само от модели получени от десет независими обучения на най-добрата архитектура от определено оптимизационно изпълнение.

Изпълнение	MAE	RMSE	R ²
1	15.636	29.538	0.884
2	16.652	27.136	0.902
3	15.832	26.018	0.910

Таблица 5.13. Резултати за станция Wanliu на ансамбъла съставен само от модели получени от десет независими обучения на най-добрата архитектура от определено оптимизационно изпълнение.

Изпълнение	MAE	RMSE	R ²
1	13.350	21.359	0.931
2	13.835	21.843	0.928
3	13.746	21.623	0.929

Таблица 5.14. Резултати за станция Changping на ансамбъла съставен само от модели получени от десет независими обучения на най-добрата архитектура от определено оптимизационно изпълнение.

Изпълнение	MAE	RMSE	R ²
1	13.888	26.805	0.891
2	14.432	28.850	0.874
3	13.126	24.649	0.908

Таблица 5.15. Резултати за станция Dongsi на ансамбли съставени от k най-добрите модели от всяко едно оптимизационно изпълнение.

k	MAE	RMSE	R ²
1	15.118	25.404	0.9144
2	14.875	25.065	0.9167
3	14.837	24.912	0.9177
4	14.858	25.079	0.9166
5	14.857	25.236	0.9156
6	14.939	25.386	0.9146
7	14.871	25.232	0.9156
8	14.863	25.205	0.9158
9	14.910	25.421	0.9143
10	14.985	25.621	0.9130

Таблица 5.16. Резултати за станция Wanliu на ансамбли съставени от k най-добрите модели от всяко едно оптимизационно изпълнение.

k	MAE	RMSE	R ²
1	13.876	21.529	0.9300
2	13.498	21.034	0.9332
3	13.355	20.945	0.9338
4	13.265	20.841	0.9344

5	13.226	20.783	0.9348
6	13.185	20.786	0.9348
7	13.177	20.763	0.9349
8	13.167	20.739	0.9351
9	13.175	20.741	0.9351
10	13.217	20.836	0.9345

Таблица 5.17. Резултати за станция Changping на ансамбли съставени от k най-добрите модели от всяко едно оптимизационно изпълнение.

k	MAE	RMSE	R²
1	13.859	25.052	0.9049
2	13.454	24.928	0.9059
3	13.391	25.000	0.9053
4	13.384	25.140	0.9043
5	13.351	25.308	0.9030
6	13.375	25.473	0.9017
7	13.401	25.665	0.9002
8	13.436	25.839	0.8988
9	13.475	26.031	0.8973
10	13.514	26.275	0.8954

Валидиране на хибридна схема за запълване на липсващи стойности

За валидиране на предложената хибридна схема за запълване на липсващи данни са проведени два типа експерименти:

- директна оценка – чрез запълване на изкуствено създадени дупки;
- индиректна оценка – чрез представянето на модели, обучени със запълнените данни.

Директна оценка

Премахнати са ~5% от валидните стойности чрез генериране на случайни „дупки“ с големина следващи геометрично разпределение с $p = 0.05$.

За запълване на липсващите стойности са използвани три стратегии: линейна интерполация, средна стойност между предишната налична валидна стойност и осреднена стойност за времевата точка, както и хибриден подход, комбиниращ двете горни стратегии.

Всеки метод е тестван 100 независими пъти и оценен със средната стойност на R^2 , като за статистическо сравнение е използван Kruskal–Wallis тест (KW).

Хибридна стратегия за запълване на липсващи данни в повечето случаи е сравнима с линейната интерполация, като я превъзхожда при озон и температура, характеризиращи се с по-изразени сезонни закономерности. Методът със средна стойност показва най-слаби резултати за почти всички замърсители, с изключение на озона, където превъзхожда останалите методи.

Индиректна оценка

Проведени са два допълнителни експеримента върху станция Changping:

- оптимизирани са модели използващи данни, за които липсващите стойности са запълнени само със стратегията с линейна интерполация;
- оптимизирани са модели използващи данни, за които липсващите стойности са запълнени само със стратегията със средна стойност.

От получените резултати не се забелязват значими разлики между хибридна стратегия и линейната интерполация ($p > 0.05$ за всички метрики). Осреднената стратегия от своя страна показва по-слаби резултати спрямо хибридна по метриката MAE ($p = 0.0014$).

Избор на входни променливи

Проведени са два допълнителни експеримента за оценка на предложената стратегия за подбор на входни променливи чрез случайно търсене:

- моделите използват като входни данни само данните за $PM_{2.5}$;
- моделите използват като входни данни всички налични 12 променливи.

Получените резултати показват, че включването на допълнителни променливи подобрява представянето на модела (за всички метрики $p < 0.05$). Използването на всички променливи води до резултати, сходни с основния експеримент ($p > 0.5$ за всички метрики), но изисква значително повече време за обучение (средно 1.84 ч спрямо 0.84 ч при подбор на променливи чрез случайно търсене, $p = 2.28 \times 10^{-7}$).

Включване на пространствена информация

За оценка на влиянието на пространствената информация е проведен експеримент, при който моделите се еволюират с фиксирана големина на околността със стойност 0. Резултатите показват, че включването на пространствена информация от съседни станции значително подобрява представянето на модела ($p < 0.05$ за всички метрики).

5.5. Изводи към пета глава

По-важните изводи и резултати, получени в пета глава на дисертационния труд могат да бъдат обобщени както следва:

- Замърсяването на въздуха оказва отрицателно влияние върху човешкото здраве и околната среда, което налага нуждата от разработване на ефективни системи за прогноза на качеството на въздуха, които биха позволили вземането на подходящи мерки;
- Предложен е хибриден дълбок пространствено-темпорален модел базиран на конволюционна НМ и LSTM мрежа за прогнозиране на замърсяването на въздуха с автоматичен подбор на входни променливи и оптимизация на хиперпараметрите на модела;
- Предложена е хибридна стратегия за запълване на липсващи стойности във времеви редове, която е приложена за използваните множества данни за обучение на модела;
- Експерименталните резултати върху общодостъпен масив от данни показват, че дори и при ограничени изчислителни ресурси еволюираните архитектури водят до получаване на добри и постоянни резултати;
- Включването на еволюираните архитектури в различни ансамбли, състоящи се от модели с еднакви архитектури и модели с различни архитектури допълнително подобрява резултатите като моделите се доближават до резултатите, получени с някои съвременни дълбоки модели, които използват същия масив от данни, а в някои случаи дори и ги превъзхождат;
- Хибридната стратегия за запълване на стойности има предимства пред линейната интерполация, особено при данни с ясно изявена сезонност, без да отстъпва в много от останалите случаи;
- Експерименталните резултати показват, че случайното търсене е проста и резултатна стратегия за подбор на входни променливи, а включването на пространствена информация подобрява значително прогнозните резултати, получени с моделите.

ЗАКЛЮЧЕНИЕ

Дисертационният труд е посветен на изследването и разработването на еволюционни подходи за автоматизирано проектиране и оптимизация на архитектури на НМ. Основната цел на дисертационния труд за разработване на еволюционна стратегия за оптимизиране на архитектури на НМ с генетични алгоритми и нейната адаптация към различни приложни области е постигната чрез изпълнение на комплекс от взаимносвързани изследователски задачи. Направен е систематичен литературен обзор върху съвременните невронно-мрежови модели и метаевристични алгоритми, който позволи идентифицирането на съществуващите ограничения на класическите методи и очерта необходимостта от разработване на нови, по-гъвкави решения. Анализирани са съществуващите подходи за автоматизация на проектирането на архитектури, като върху тази основа е предложен дизайн на еволюционна стратегия, включваща специфични механизми за представяне на решенията, както и модифицирани оператори за кръстосване и мутация. Разработената стратегия е приложена в три основни области: управление на автономни агенти, разпознаване на човешки дейности и прогнозиране на замърсяването на въздуха. За всяка от тези задачи са дефинирани съответните модели на НМ, адаптирани към спецификата на данните и изискванията на приложението. В резултат на проведените експерименти е демонстрирано, че еволюционно оптимизираните архитектури постигат по-висока ефективност в сравнение с ръчно проектираните модели, като същевременно намаляват необходимостта от

човешка експертиза и времето за настройка. По този начин е потвърдена валидността на основната хипотеза на дисертационния труд, че оптимални архитектури на НМ могат да бъдат определяни чрез метаевристични алгоритми, които използват адаптивни оператори и подходящи схеми на кодиране. Дисертационният труд не само потвърждава потенциала на еволюционните стратегии като ефективен инструмент за оптимизация на архитектури на НМ, но и създава стабилна основа за бъдещи изследвания и практически реализации в различни сфери на изкуствения интелект и машинното обучение. Постигнатите резултати имат стойност както за развитието на теоретичните основи на метаевристичната оптимизация на НМ в различни контексти, така и за приложението им в реални, сложни и динамични системи.

ПРИНОСИ ПО ДИСЕРТАЦИОННИЯ ТРУД

▪ *Научни приноси:*

- Предложен е метод за оптимизация на архитектурата на НМ с използване на генетичен алгоритъм за еволюция и усложняване на решенията от по-прости към по-сложни, който използва модифициран оператор за кръстосване за решения с вариращи дължини и адаптивна мутация с три стратегии за промени в архитектурите на НМ;
- Предложен е метод за еволюиране на НМ за управление на автономни агенти, който използва биологично вдъхновена индиректна схема на кодиране, осигуряваща възможност за развитие на НМ с отчитане на взаимодействията със средата с цел адаптиране на агента към специфична среда;
- Предложен е метод за автоматична оптимизация на архитектурата на конволюционни НМ за разпознаване на човешки дейности чрез еволюционен процес, който усложнява прости архитектури с добавяне на нови слоеве с използване на модифицирано кръстосване за решения с различна дължина и адаптивна мутация с три равновероятни стратегии за модифициране на слой, добавяне на слой и премахване на слой от архитектурата на НМ;
- Предложен е подход за включване на еволюирани архитектури за хибриден дълбок пространствено-темпорален модел за прогнозиране на замърсяването на въздуха в различни ансамбли, състоящи се от модели с еднакви архитектури и модели с различни архитектури.

▪ *Научно-приложни приноси:*

- Предложен е хибриден дълбок пространствено-темпорален модел базиран на конволюционна НМ и LSTM мрежа за прогнозиране на замърсяването на въздуха с автоматичен подбор на входни променливи и оптимизация на хиперпараметрите на модела;
- Предложена е хибридна стратегия за запълване на липсващи стойности във времеви редове, която е приложена за обучение на хибридният дълбок пространствено-темпорален модел за прогнозиране на замърсяване на въздуха;
- Предложена е стратегия за подбор на входни променливи при прогнозиране на замърсяването на въздух с хибриден дълбок пространствено-темпорален модел;
- Предложена е стратегия за включване на пространствена информация при прогнозиране на замърсяването на въздух с хибриден дълбок пространствено-темпорален модел.

▪ *Приложни приноси:*

- Разработен е прототип за експериментално оценяване на предложената биологично вдъхновена индиректна схема на кодиране за еволюиране на НМ за управление на автономни агенти върху симулация на изкуствен свят, който показва, че с използване на проста имплицитна фитнес функция успешно се еволюират агенти способни да разграничават различни обекти и се генерират разнообразни и комплексни архитектури с малък брой параметри спрямо други възможни подходи за еволюиране на нервна система за управление на автономни агенти;
- Разработен е прототип за експериментално оценяване на еволюционно базирания дизайн на конволюционни НМ за разпознаване на човешка дейност, който показва значително по-добри резултати в сравнение с други дълбоки архитектури;
- Разработен е прототип за експериментално оценяване на предложения хибриден дълбок пространствено-темпорален модел за прогнозиране на замърсяването на въздуха, който показва, че дори и при ограничени изчислителни ресурси еволюираните архитектури водят до получаване на добри и постоянни резултати.

СПИСЪК НА ПУБЛИКАЦИИ ПО ДИСЕРТАЦИОННИЯ ТРУД

1. **Tsokov, S.,** M. Lazarova, A. Aleksieva-Petrova, Optimizing neural network architectures using an evolutionary algorithm with a modified crossover operator, *Journal Computer and Communication Engineering*, Vol. 15, No.2, 2021, pp.18-20, ISSN 1314-2291.
2. **Tsokov, S.,** Evolving neural network control systems for autonomous agents: A review, *Journal Computer and Communications Engineering*, Vol. 13, No.1, 2019, pp. 36-41, ISSN 1314-2291
3. **Tsokov, S.,** A. Aleksieva-Petrova, M. Lazarova, An activity-dependent model for the evolution of an artificial nervous system for autonomous agents, 9th International Scientific Conference Computer Science'2020, Velingrad, Bulgaria, 18-21 October, 2020, pp. 17-23, ISBN: 978-619-167-433-6.
4. **Tsokov, S.,** M. Lazarova, A. Aleksieva-Petrova, A novel biologically inspired developmental indirect encoding for the evolution of neural network controllers for autonomous agents, *Proceedings of the Technical University of Sofia*, Vol. 71, No. 1, 2021, ISSN 1311-0829, <https://doi.org/10.47978/TUS.2021.71.01.005>.
5. **Tsokov, S.,** M. Lazarova, A. Aleksieva-Petrova, Evolving 1D convolutional neural networks for human activity recognition, *Proc. of the 22nd International Conference on Computer Systems and Technologies (CompSysTech '21)*, Association for Computing Machinery, New York, NY, USA, 2021, pp. 49–54, <https://doi.org/10.1145/3472410.3472413>.
6. **Tsokov, S.,** M. Lazarova, A. Aleksieva-Petrova, An evolutionary approach to the design of convolutional neural networks for human activity recognition, *Indian Journal of Computer Science and Engineering*, Vol. 12, No. 2, 2021, pp. 499-517, doi: 10.21817/indjcse/2021/v12i2/211202145.
7. **Tsokov, S.,** M. Lazarova, A. Aleksieva-Petrova, Accelerometer-based human activity recognition using 1D convolutional neural network, *IOP Conference Series: Materials Science and Engineering*, Vol. 1031, 2021, <https://iopscience.iop.org/article/10.1088/1757-899X/1031/1/012062>.
8. **Tsokov, S.,** M. Lazarova, A. Aleksieva-Petrova, A hybrid spatiotemporal deep model based on CNN and LSTM for air pollution prediction, *MDPI Sustainability (Switzerland)*, Vol. 14, No. 9, art. no. 5104, 2022, doi: 10.3390/su14095104.

SUMMARY

OPTIMIZATION OF NEURAL NETWORK ARCHITECTURES THROUGH EVOLUTIONARY ALGORITHMS

Stefan Alipiev Tsokov

The rapid advancement of deep learning has highlighted the need for discovering optimal neural network architectures. However, designing such architectures remains a complex, resource-intensive, and time-consuming task that demands substantial expertise and computational power. This challenge underscores the importance of automating and optimizing the architecture design process through the use of intelligent metaheuristic techniques. Evolutionary algorithms, including genetic algorithms, offer a promising solution, as they enable efficient exploration of large and complex architectural and parameter spaces without requiring direct human intervention.

A key contribution of this research is the development of an evolutionary method that employs a modified crossover operator suitable for variable-length architectures, along with an adaptive mutation mechanism featuring three strategies: modifying, adding, and removing layers. This allows architectures to increase in complexity only when necessary, ensuring an optimal balance between exploration and exploitation.

The proposed strategy is applied across three domains: autonomous agent control, human activity recognition, and air pollution forecasting. For each application, specialized neural network models were tailored to the specific characteristics of the data and problem requirements. This led to the development of: (1) a biologically inspired scheme for evolving neural networks for agent control; (2) an evolutionary method for automatic optimization of CNN architectures for activity recognition; and (3) a hybrid spatiotemporal model for air pollution forecasting that combines CNN and LSTM, with automatic selection of input variables, hyperparameters, and spatial information, as well as ensemble integration. Additionally, a hybrid data imputation strategy was proposed, demonstrating advantages over traditional linear interpolation methods.

The conducted analyses and experiments demonstrate that the evolutionarily optimized architectures often outperform manually designed and classical methods, achieving higher accuracy, stability, and adaptability. In the human activity recognition task, the results are comparable to or better than those of modern deep models. In air pollution forecasting, the hybrid spatiotemporal models developed using the proposed approach perform well even with limited computational resources, while the inclusion of ensembles further improves effectiveness.

In summary, the dissertation demonstrates that metaheuristic approaches and adaptive evolutionary strategies can successfully automate neural network architecture design, yielding efficient, interpretable, and applicable models. These methods provide flexibility, high levels of automation, eliminate the proxy gap, maintain structural validity, and establish a strong foundation for future research and real-world.