Софийски университет
„Св. Климент Охридски“

Стопански факултет

Катедра „Икономика и управление по отрасли“

Автореферат на дисертация

за присъждане на образователна и научна степен „Доктор“

професионално направление 3.8 „Икономика“

докторска програма „Икономика и управление (индустрия)“

Невронномрежови модели за икономическо прогнозиране

Докторант

Илиян Ненов

Научен ръководител

проф. д-р Георги Менгов

2025 г.

София, България

Съдържание

1 Общи характеристики на дисертацията **2**

1.1 Актуалност на изследването 2

1.2 Цели и задачи 3

1.3 Методология на изследването 4

1.4 Ограничения на изследването 4

1.5 Структура на дисертацията 5

2 Описание на дисертационния труд **7**

2.1 Обзор на методите за прогнозиране на икономически данни 7

2.1.1 Обучение с учител 7

2.1.2 Самообучаващи се модели 9

2.1.3 Дълбочинно обучение 10

2.1.4 Обучение с подкрепление 12

2.1.5 Подходи от математическата невронаука 13

2.2 Невронномрежов модел за прогнозиране цените на акции 14

2.2.1 Основни моменти 14

2.2.2 Модел за прогнозиране 15

2.2.3 Резултати 19

2.2.4 Изводи и заключения 21

2.3 Макроикономическо прогнозиране с недостатъчни данни 22

2.3.1 Прогнозиране на макроикономически индикатори 22

2.3.2 Резултати 24

2.3.3 Изводи и заключения 25

2.4 Прогнозиране на икономиките на Европейски Съюз в условия на икономическа нестабилност 26

2.4.1 Точност на макроикономическите прогнози на Европейски съюз 26
2.4.2 Прогнозиране на макроикономически индикатори 26
2.4.3 Резултати 28
2.4.4 Изводи и заключения 29
Заключение 33
Научни и научноприложни приноси 33
Списък на публикациите по темата на дисертацията 34
Благодарности 36

Дисертационният труд е на тема *„Невронномрежови модели за икономическо прогнозиране“* и се състои от увод, четири глави, заключение, научни приноси, списък с публикации и библиография. Общият обем на разработката е 131 страници, от които 105 са основен текст. Библиографията съдържа 177 източника, от които 10 на български език и 167 на английски език. Основният текст включва общо 33 фигури, 10 таблици и 74 индексирани математически уравнения.

Дисертацията е обсъдена и насочена за публична защита на катедрен съвет с Протокол № xxx/xx.xx.2025 г

Глава 1

Общи характеристики на дисертацията

Настоящата дисертация е посветена на изследването на невронномрежови модели за икономическо прогнозиране. Обект на изследването е специфичен тип невронни мрежи, известни в математическата невронаука като „пропусклив дипол“ (gated dipole), които се прилагат с цел повишаване на точността на прогнозите в условия на висока неопределеност и при ограничен обем данни. Предложеният подход е новаторски за иконометрията, като позволява както усъвършенстване на традиционните иконометрични модели, така и преодоляване на някои от основните ограничения, свързани с директното прилагане на невронномрежово прогнозиране в икономиката – като трудния баланс между стабилност и адаптивност (пластичност), както и нуждата от големи обеми обучителни данни.

1.1 Актуалност на изследването

Прогнозирането на икономически процеси е една от фундаменталните задачи в иконометрията. Сложността на проблема нараства успоредно с развитието на технологиите и икономическите системи. В резултат на това, традиционните иконометрични модели често се оказват недостатъчни, за да опишат нелинейните процеси.

Съвременните методи, базирани на машинно обучение, предлагат значителни възможности, но имат редица ограничения за директно използване в задачи за прогнозиране в икономиката. Основните проблеми са в необходимостта от големи

обеми данни, затрудненатa адаптивност при динамични условия и проблемите свързани с интерпретация на резултатите.

Това налага изследването на алтернативни методи, взаимствани от математическата невронаука където методи разчитащи на адаптивно обучение са добре изследвани. Настоящата дисертация разглежда подход, който предлага балансирано поведение между стабилност и адаптивност, без да изисква големи тренировъчни масиви.

1.2 Цели и задачи

Основната цел на дисертацията е да се изследва приложимостта на пропускливия дипол за прогнозиране на икономически процеси и са поставени следите изследователски задачи:

1. Да се извърши критичен анализ на известните в научната литература модели за прогнозиране на макроикономически и финансови данни.

2. Да се изследват възможностите на пропускливия дипол за моделиране и прогнозиране на движението на цената на акции, търгувани на фондова борса.

3. Да се приложи диполният модел в казус с данни, недостатъчни за класически иконометричен анализ.

4. С предложения подход да се изследва прогнозируемостта на макроикономическите величини на малка отворена икономика по време на външен икономически шок.

5. Да се идентифицират макроикономически величини, които ефективно се прогнозират с предложения невронномрежов подход по време на икономическия шок следствие от пандемията в периода 2020-2022 г.

6. Да се изследват способностите на пропускливия дипол да прогнозира макроикономически величини в ситуация на хроничната нестабилност, причинена от различни и частично припокриващи се фактори – пандемия, война, енергийна криза и нарушени вериги за доставки.

1.3 Методология на изследването

Методологията на дисертационния труд се основава на количествен сравнителен анализ и експериментално валидиране. Използвани са следните основни методи:

- Теоретичен анализ и систематизация: Критичен преглед на научната литература с фокус върху методите за икономическо прогнозиране, техните теоретични основи и практически приложения и ограничения.
- Математическо моделиране: Адаптиране на система от нелинейни диференциални уравнения, описващи динамиката на пропускливия дипол, за прогнозиране на икономически данни.
- Експериментално валидиране: Провеждане на контролирани експерименти за прогнозирането на икономически индикатори с използване на реални данни от финансови пазари и макроикономически показатели.
- Сравнителен анализ: Систематично сравнение на прогнозните способности на предложения модел с утвърдени статистически методи и официални прогнози на международни институции.
- Статистическа валидация: Прилагане на непараметрични статистически тестове за оценка на значимостта на разликите в прогнозната точност.
- Оптимизация: Използване на стохастични оптимизационни методи за настройка на параметрите на модела според специфичните условия на всеки експеримент.

1.4 Ограничения на изследването

В хода на изследването са отчетени и някои ограничения, свързани с приложимостта на предложения модел. На първо място, неговата ефективност е демонстрирана предимно в условия на висока неопределеност – нестабилни и емоционално водени пазари, търговия с акции в кризисни моменти и икономики в преход. В стабилни и добре функциониращи икономически условия предимствата на модела са по-слабо изразени.

На второ място, въпреки че е предложен механизъм, чрез който диполният модел може да отчита фактори, свързани с неопределеността, остава отворен въпросът доколко тези фактори могат да бъдат количествено измерени и ефективно използвани за прогнозиране. Поради това, в дисертацията, всички прогнозни на диполният модел са направени без този механизъм.

И накрая, макар моделът да е изпробван в различни експерименти не са обхванати всички възможни икономически условия. Това поставя естествени граници пред генерализацията на резултатите.

1.5 Структура на дисертацията

Дисертационният труд е структуриран в увод, четири последователно надграждащи глави, заключение, списък на научните приноси и библиография:

Първа глава прави обзор и критичен анализ на съществуващите методи за икономическо прогнозиране. Систематизират се предимствата и недостатъците на основните класове модели - от класическите иконометрични подходи до съвременните методи за дълбочинно обучение. Разгледани са и спомагателни методи за намаляване на размерността на данните, откриване на аномалии и други, които често са в помощ при прогнозиране на икономически данни. Главата обосновава необходимостта от разработване на алтернативни подходи и въвежда теоретични подходи от математическата невронаука като основа за предложения нов подход.

Втора глава въвежда и тества модел с рекурентен пропусклив дипол за прогнозиране цените на акции на публични компании. Детайлно се описва архитектурата и функционирането на модела, както и методологията за неговото калибриране. В тази глава се изследва неговата ефективност в два силно контрастни сценария - прогнозиране на цени на силно волатилни финансови активи и цени на стабилни, високоликвидни акции. В тази глава се използва най-сложният диполен модел, използван в рамките на дисертацията. Това позволява включването на пълния набор от диференциални уравнения, описващи динамиката между отделните му компоненти. В следващите глави, поради естеството на задачите и използваните данни, се използват опростени версии на модела, използващи подмножество от невроните и връзките, описани в настоящата глава.

Трета глава пренася фокуса към макроикономическо приложение и изследва потенциала на модела в екстремни условия на информационен дефицит. В тази глава се прогнозират основни макроикономически показатели на Черна гора в период на силни икономически шокове (2006-2013). Основният акцент в тази глава е използването на диполният модел за прогнозиране на макроикономически индикатори с ограничен обем данни, където традиционните иконометрични подходи са трудно приложими. В допълнение се разглежда и механизмът, по който към диполният модел може да се добавят ненаблюдавани (латентни) променливи, стохастични смущения, екзогенни шокове и влиянието на несъвършена информация върху прогнозите. Тъй като в рамките на тази дисертация не се адресира измерването на такива фактори този механизъм е изключен при експериментите и прогнозите на дипола са получени без неговото използване.

Четвърта глава разширява мащаба на анализа, като тества способностите на модела в най-трудния възможен сценарий: прогнозиране на макроикономическите показатели на всички 27 страни-членки на Европейския съюз (ЕС-27) по време на кризисния период, породен от пандемията от COVID-19. Резултатите се сравняват директно с грешките на официалните прогнози на Европейската комисия. В това изследване са използвани публично достъпни данни от Евростат.

Заключението синтезира основните изводи от изследването, формулира научните и научно-приложните приноси на дисертацията и представя списък на публикациите по темата.

Глава 2

Описание на дисертационния труд

2.1 Обзор на методите за прогнозиране на икономически данни

2.1.1 Обучение с учител

Обучението с учител представлява основен подход за прогнозиране на икономически величини, при който се цели извеждане на функция $f : A \to B$, съпоставяща вектор от стойности на независими променливи (множеството A) към стойност на зависима променлива (множеството B) с минимална прогностична грешка. Параметрите на функцията се оценяват чрез обучителен процес върху предварително дефинирана обучителна извадка от наблюдения, като оптимизацията се извършва чрез минимизиране на подходяща функция на грешката. За валидиране на обобщаващата способност на модела се използва отделна тестова извадка, върху която се оценява точността на прогнозите. В контекста на икономическите изследвания този тип модели намират приложение при прогнозиране на времеви редици, прогнозиране на търсене, класификация на икономически субекти и други аналитични задачи, базирани на исторически данни.

Регресионният анализ е класически инструмент за разкриване на зависимости между икономически показатели. Линейната регресия моделира връзката между зависима и независими променливи чрез уравнението:

$$Y = \beta_0 + \beta_1 X_1 + ... + \beta_n X_n + \epsilon, \tag{2.1}$$

където Y е прогнозирана стойност, X_i са стойносите на зависимите променливи, β_i са регресионни коефициенти, а ϵ е случаен шум. Полиномната регресия разширява този модел, позволявайки нелинейни зависимости, докато хребетната регресия въвежда L2-регуларизация за по-добра генерализация:

$$L = \sum_{i=1}^{n}(y_i - \beta_0 - \sum_{j=1}^{p}\beta_j x_{ij})^2 + \lambda \sum_{j=1}^{p}\beta_j^2. \tag{2.2}$$

ARIMA моделите са статистически инструменти, които се използват за прогнозиране на стойности във времето – например цени, продажби или икономически показатели. Те работят, като анализират предишни стойности от една времева поредица и търсят модели или закономерности в тях. ARIMA съчетава три основни компонента: автокорелация (как предишните стойности влияят на настоящите), тренд (дали данните се покачват или спадат с времето) и случайни колебания. Моделът е особено полезен, когато данните не са напълно стабилни, но с помощта на подходящи трансформации те могат да бъдат „успокоени“, за да се разкрият подлежащите зависимости, които позволяват по-точно прогнозиране.

Методът на подвижните средни стойности се използва, за да се изгладят резките колебания в данни, които се променят с времето – например цени или продажби. Вместо да се гледа всяка стойност поотделно, се изчислява средна стойност за определен брой последователни моменти. Така се получава по-плавна линия, която показва общата тенденция, без да се влияе толкова силно от случайни промени.

Класификационните методи се използват, когато трябва да се определи към коя категория или група принадлежи дадено наблюдение – например дали клиент ще върне заем или не. Логистичната регресия оценява вероятността нещо да се случи на база различни фактори. Наивният байесов класификатор използва прости правила за изчисляване на вероятности, докато методите с дървета на решения и т.нар. „случайни гори“ (random forrest) вземат решения чрез поредица от логически въпроси и осигуряват висока точност, дори когато данните са сложни.

Методи като машините с поддържащи вектори и невронните мрежи разширяват възможностите на обучението с учител, като позволяват работа с по-сложни зависимости в данните. Машините с поддържащи вектори се стремят да намерят най-добрия начин за разделяне на различни групи чрез „граница“, която ги разделя

оптимално добре. Невронните мрежи, вдъхновени от начина, по който работи човешкият мозък, използват слоеве от свързани „изкуствени неврони“, за да откриват сложни връзки, които не могат да се опишат с прости математически формули.

Освен това съществуват и т.нар. ансамблови методи, които комбинират няколко модела заедно, за да подобрят точността на прогнозите. Те намират широко приложение в области като финансов анализ, оценка на кредитен риск и прогнози за пазара.

В заключение, обучението с учител е основата на съвременните икономически системи за прогнозиране. То интегрира класически статистически подходи и модерни машинно-обучаващи се алгоритми, осигурявайки надеждни инструменти за анализ и вземане на решения в условия на динамична и несигурна икономическа среда.

2.1.2 Самообучаващи се модели

Обучението без учител е важен подход, при който компютърните модели анализират данни, за да открият скрити модели, групи и необичайни случаи, без да им е казано предварително какъв трябва да е резултатът. Тези методи са особено полезни, когато трябва да се проучи сложна система или да се подготвят данните за по-нататъшен анализ. Един от основните им видове е групирането (клъстериране), при което данните се разделят на групи според това колко си приличат. Алгоритми като този с най-близките съседи сравняват обектите по техните характеристики и ги поставят в една и съща група, ако са „близо“ един до друг. Подобни методи се използват широко в икономиката – например за сегментиране на пазара или за откриване на необичайни отклонения в данните.

Намаляването на размерността е техника, която помага да се опрости анализът на сложни данни с много променливи. Метод като анализа на главните компоненти (PCA) открива кои фактори в данните са най-важни и обобщава информацията, като запазва основните зависимости. Вместо да се гледат всички първоначални характеристики, методът създава нови, по-малко на брой, но независими една от друга променливи, които съдържат по-голямата част от важната информация. Това улеснява визуализирането и разбирането на данните, въпреки че при този процес може да се загубят някои по-малко значими детайли.

Откриването на аномалии е важно, когато трябва да се разпознаят необичайни

събития или потенциални рискове в данните – например измамни транзакции или рязко отклонение в икономически показатели. Това се прави чрез сравняване на всяка стойност с най-близките до нея, за да се прецени дали се държи различно от останалите. Друг подход е да се изчисли колко „гъсто“ са разположени стойностите около дадена точка – ако тя е твърде изолирана, вероятно е аномалия. Съществуват и по-мощни методи, като изолационната гора или локалният коефициент на отклонение, които са ефективни дори при много големи и сложни набори от данни.

Извличането на асоциативни правила помага да се открият скрити връзки между икономически показатели – например кои събития често се случват заедно. Алгоритми като Apriori намират често срещани комбинации от данни и създават прости правила, които могат да се използват за прогнози. При анализа на текстове, тематичното моделиране позволява автоматичното откриване на основните теми в голям обем документи. Техники като Latent Dirichlet Allocation се използват например за анализ на новини или научни статии, като извеждат основните идеи без нужда от ръчно четене на всеки текст.

Мрежовият анализ разкрива структурата и динамиката на икономическите системи чрез изследване на връзките между агенти, определяне на централност и идентифициране на общности. Този подход е особено ценен за анализ на вериги за доставки, финансови и търговски мрежи, както и за открояване на ключови играчи в икономическите процеси.

Самообучаващите се модели са незаменим инструмент за разкриване на скрити структури, редуциране на сложността и идентифициране на аномалии в икономическите данни, като по този начин създават основа за по-ефективно прогнозиране и вземане на решения.

2.1.3 Дълбочинно обучение

Дълбочинното обучение е съвременен метод за анализ на сложни икономически данни. Той се базира на изкуствени невронни мрежи, които могат да откриват сложни връзки между различни данни и да правят прогнози, например за финансови пазари или икономически тенденции. Основните трудности при този метод са балансирането между запомнянето на важна информация и адаптирането към нови данни, както и обяснението защо моделът дава точно тези резултати (често наричано

„черна кутия“).

Рекурентните невронни мрежи (RNN) са специални модели, които обработват данни, подредени във времето (времеви редици). Те използват вътрешна „памет“, за да разберат какво се е случило преди това, но имат проблеми с „запомнянето“ на информация за дълги периоди.

Мрежите с дълга краткосрочна памет (LSTM) са подобрена версия на RNN, които по-добре запомнят важните неща за по-дълго време и са по-устойчиви на шум и липсващи данни. Те са полезни за прогнози в икономиката, но имат нужда от големи количества данни и понякога могат да се „свръхнагодят“ – т.е. да започнат да запомнят твърде много детайли от обучителните данни, вместо да научат общи закономерности.

Конволюционните невронни мрежи (CNN) са модели, които могат автоматично да извличат важни характеристики от сложни данни, които имат структура на матрица (например изображения или икономически данни, подредени в таблици). Те постигат добри резултати с данни, в които има шум или са непълни, но също изискват много данни и стабилни условия на обучение.

Генеративните състезателни мрежи (GAN) са два модела, които „се състезават“ помежду си – единият създава нови данни, а другият проверява дали те са истински. Това позволява създаването на реалистични синтетични данни, които помагат за тестване и усъвършенстване на други модели. GAN са много мощни, но също така изискват много данни и внимателно използване.

Автоенкодерите са модели, които учат да представят данните в по-компактна форма и после да ги възстановяват. Те се използват за откриване на необичайни случаи, намаляване на размерността на данните и генериране на нови примери. За да работят добре, те също имат нужда от качествени данни и понякога е трудно да се разбере как точно вземат решения.

Обобщено, дълбочинното обучение дава много нови възможности за анализ и прогнози в икономиката, но изисква много данни, голяма изчислителна мощ и още не е напълно изяснео как да се обясняват резултатите от моделите.

2.1.4 Обучение с подкрепление

Обучението с подкрепление е съвременен метод за моделиране на процеса на вземане на решения в икономиката. При този подход „агент“ (например компютърна програма) взаимодейства със своята среда и се учи да избира действия, които му носят максимална награда във времето.

За по-лесно решаване на сложни задачи, те се разделят на по-малки стъпки. Така, чрез комбиниране на решения за всяка отделна стъпка, се намира най-добрата цялостна стратегия.

Този процес може да бъде описан с помощта на математически модел, наречен Марковски процес на вземане на решения. В него се разглеждат:

- различни състояния на средата (например различни икономически ситуации);
- възможни действия на агента (като инвестиции или продажби);
- вероятности как средата може да се промени след дадено действие;
- и награди, които агентът получава в зависимост от направеното действие.

Целта е да се намери оптимална стратегия, която максимизира очакваната обща награда за бъдещето. Съществуват методи като Q-learning и SARSA, които позволяват на агента да се учи кои действия са най-ценни, дори когато не разполага с пълна информация за средата, в която работи.

Динамично-стохастичните модели се използват за описване на начина, по който се променят скрити (непряко наблюдавани) състояния във времето и как те влияят на наблюдаваните данни.

По-конкретно, тези модели разглеждат две основни неща: (1) как вътрешното състояние на системата се променя от един момент към друг, и (2) как това състояние се отразява в измерваните резултати.

Тези модели са полезни за прогнозиране на икономически показатели, като например растежа на брутния вътрешен продукт. В същото време те изискват големи количества данни и са чувствителни към предположенията, които правим за структурата и поведението на системата.

Методите на Монте-Карло са техники, които използват множество компютърни симулации, за да оценят важни статистически показатели на сложни модели. Вмес-

то да се опитваме да изчислим резултатите точно, ние събираме много случайни примери и пресмятаме средната стойност от тях.

Тези методи се прилагат широко в икономиката и финансите – например за оценка на финансовия риск, за оптимизиране на инвестиционни портфейли и за подпомагане на вземането на политически решения.

Обучението с дълбоко подкрепление (DRL) комбинира невронни мрежи и обучение с подкрепление, като позволява вземане на решения при риск и несигурност, динамично ценообразуване и управление на доставки. Многоагентното обучение с подкрепление моделира взаимодействия между множество агенти, като намира приложение в анализ на пазари, социални мрежи и персонализирани препоръки. Контекстуалните бандити и имитационните алгоритми разширяват възможностите за прогнозиране и автоматизация на икономически решения.

Обучението с подкрепление и неговите разширения предоставят мощен инструментариум за анализ и оптимизация на сложни икономически системи, като интегрират вероятностни, динамични и стохастични подходи за вземане на решения.

2.1.5 Подходи от математическата невронаука

Математическата невронаука интегрира математически, неврофизиологични и изчислителни методи за моделиране на сложната динамика на нервната система. Чрез количествени модели се описват електрофизиологични процеси, невронна активност и когнитивни функции като памет, учене и внимание. Класическият модел на Ходжкин–Хъксли използва диференциални уравнения за описване на предаването на електрически сигнали между невроните, а биологично вдъхновените модели симулират явления като пластичност, синхронизация и самоорганизация.

В технологичен и икономически контекст, невроинспирираните алгоритми намират приложение в мозъчно-компютърни интерфейси, изкуствен интелект и прогнозиране на сложни системи като финансови пазари. Моделите, вдъхновени от мозъчната динамика, позволяват създаване на адаптивни алгоритми за учене и прогнозиране, които анализират стохастични процеси и нелинейни зависимости в икономиката. Особено ценен е моделът на рекурентния пропусклив дипол, който интегрира дългосрочна памет, възбуждане, предаване и запаметяване на информация, както и емоционална памет, за симулиране на адаптивно поведение.

Математическата невронаука предоставя формална рамка за изграждане на адаптивни иконометрични модели, които симулират когнитивните способности на икономическите агенти. Тези модели са особено ефективни при анализ на времеви редици с прекъсвания, стохастични флуктуации и нелинейни зависимости, характерни за макроикономиката и финансите. Принципите на асоциативното учене и невронната пластичност, пренесени в икономиката, разкриват нови възможности за създаване на интелигентни системи, способни да се адаптират към динамичната природа на пазарите и да подпомагат вземането на решения в условия на несигурност и комплексност.

2.2 Невронномрежов модел за прогнозиране цените на акции

2.2.1 Основни моменти

Прогнозирането на финансови пазари се сблъсква с фундаментални ограничения, произтичащи от две водещи хипотези. Хипотезата за ефективния пазар (EMH) твърди, че цените напълно отразяват наличната информация, което прави реализирането на печалби над средното ниво практически невъзможно. Адаптивната пазарна хипотеза (AMH) разглежда пазарите като еволюционни системи, в които ефективността е динамична. Пазарните участници се адаптират към нови условия, което води до временни отклонения от ефективността и прави дългосрочното прогнозиране нерешимо.

И двете хипотези предполагат, че прогнозирането е изключително трудно, но адаптивните невронни модели като пропускливия дипол могат да уловят краткосрочни зависимости и аномалии, да се адаптират бързо и да прогнозират с добра точност. Моделите на Гросбърг дефинират три основни механизма на невронно взаимодействие: активиране, предаване на сигнал и запаметяване, всеки описан с нелинейни диференциални уравнения. Формалният апарат на пропускливия дипол включва:

Активиране на неврон:

$$\frac{dx_i}{dt} = -A_1 x_i + (A_2 - x_i) J_i^+ - (x_i + A_3) J_i^- . \tag{2.3}$$

Предаване на сигнал:

$$\frac{dy_i}{d_t} = B(1 - y_i) - Cx_i y_i. \tag{2.4}$$

$$y_i(t) = \frac{B}{B + Cx_i} + c_1 exp\big[-(Cx_i + B)t\big], \tag{2.5}$$

където c_1 е интеграционна константа, а $\lim_{t\to\infty} y_i(t) = \frac{B}{B+Cx_i}$.

Запомняне на информация:

$$\frac{dy_{ij}}{dt} = x_i(-D_1 y_{ij} + D_2 x_j), \tag{2.6}$$

където $y_{ij} \in [0, 1]$ е безразмерна променлива, $D_1, D_2 > 0$.

В условията на ефективен пазар пропускливият дипол може да улавя краткосрочни аномалии, а при адаптивна пазарна хипотеза – да реагира бързо на промени и да улавя динамиката в данните. Моделът е особено ефективен при смяна на режима и висока волатилност.

Прогнозиране на NASDAQ акции: Изследването сравнява ефективността на пропускливия дипол с традиционни методи като линейна регресия и авторегресия, използвайки данни за 26 компании от NASDAQ.

Графиката от тип свещи (фиг. 2.1) илюстрира динамиката на цените, като показва по-голяма волатилност във върховете на дневните цени. Механизмът на формиране на цената на борсата се определя от баланса между търсене и предлагане, а ликвидността зависи от разликата между лимитите на купувачите и продавачите. При екстремни пазарни условия се наблюдават свръхтърсене или свръхпредлагане, което води до резки движения на цените. Пропускливият дипол се отличава с възможността да се адаптира към такива динамични промени, като улавя краткосрочни зависимости и аномалии, които традиционните модели често пропускат.

2.2.2 Модел за прогнозиране

Архитектурата на пропускливия дипол за прогнозиране на финансови данни е илюстрирана на фиг. 2.2, където са показани връзките между отделните неврони.

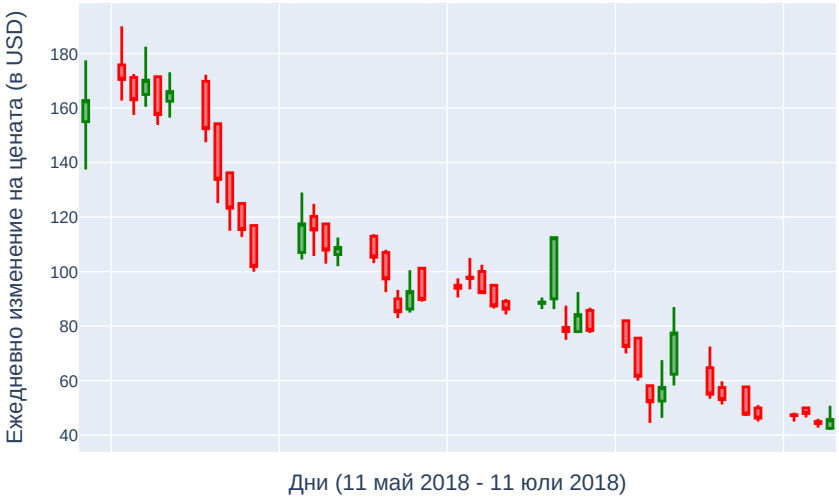

Фигура 2.1: Изменение на цената на NASDAQ акция търгувана за период от два месеца (43 работни дни)

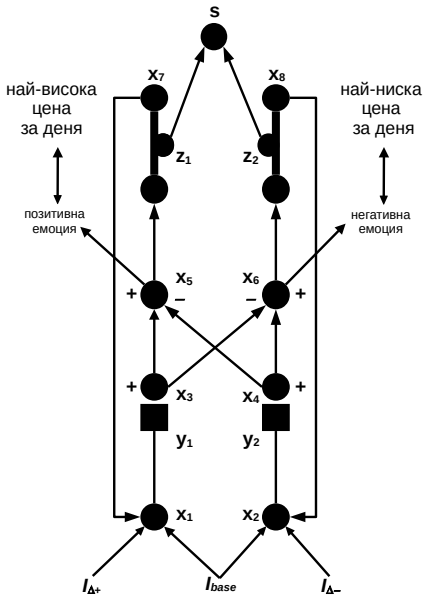

Фигура 2.2: Диаграма на пропусклив дипол с връзки между отделните неврони.

Входните сигнали към невроните x_1 и x_2 се дефинират чрез:

$$\dot{x}_1 = -x_1 + I_{base} + \delta I_{\Delta^+} + Mx_7 \tag{2.7}$$

$$\dot{x}_2 = -x_2 + I_{base} + \delta I_{\Delta^-} + Mx_8. \tag{2.8}$$

Средносрочната памет (MTM) се моделира чрез:

$$\dot{y}_1 = b_1 (1 - y_1) - c_1 x_1 y_1 \tag{2.9}$$

$$\dot{y}_2 = b_2 (1 - y_2) - c_2 x_2 y_2. \tag{2.10}$$

Позитивната и негативната емоция на дипола са:

$$o_1 = [x_5]^+ \tag{2.11}$$

$$o_2 = [x_6]^+, \tag{2.12}$$

където $[\xi]^+ = \max(\xi, 0)$ е ReLU функция.

Изходните сигнали на останалите неврони са:

$$\dot{x}_3 = -x_3 + x_1 y_1 \tag{2.13}$$

$$\dot{x}_4 = -x_4 + x_2 y_2 \tag{2.14}$$

$$\dot{x}_5 = -x_5 + (1 - x_5) x_3 - (x_5 + 1) x_4 \tag{2.15}$$

$$\dot{x}_6 = -x_6 + (1 - x_6) x_4 - (x_6 + 1) x_3 \tag{2.16}$$

$$\dot{x}_7 = -x_7 + Go_1 + Lz_1 \tag{2.17}$$

$$\dot{x}_8 = -x_8 + Go_2 + Lz_2. \tag{2.18}$$

Дългосрочната памет (LTM) се моделира чрез:

$$\dot{z}_1 = S_1 (-h_1 z_1 + h_2 o_1) \tag{2.19}$$

$$\dot{z}_2 = S_2 (-h_1 z_2 + h_2 o_2) . \tag{2.20}$$

$$S_i = \begin{cases} 1 & \text{, ако } o_i^t > 0 \\ 0 & \text{, ако } o_i^t \leq 0 \end{cases}, \tag{2.21}$$

съответно за $i = 1$ и 2.

Входният сигнал I_{base} се определя от обема на търговията:

$$I_{base}^{(k)} = \alpha_1 \ln(V^{t-1}). \tag{2.22}$$

Прогнозата за най-висока и най-ниска цена се определя чрез:

$$\widehat{P}_H^t = P_O^t + \alpha_2 \widehat{\Delta}_{OH}^t. \tag{2.23}$$

$$\widehat{P}_L^t = P_O^t - \alpha_2 \widehat{\Delta}_{OL}^t. \tag{2.24}$$

Входните сигнали I_{Δ^+} и I_{Δ^-} се дефинират чрез:

$$I_{\Delta^+} = \begin{cases} \alpha_1(P_O^t - P_C^{t-1}) & \text{, ако } P_O^t > P_C^{t-1} \\ 0 & \text{, ако } P_O^t \leq P_C^{t-1} \end{cases} \tag{2.25}$$

$$I_{\Delta^-} = \begin{cases} \alpha_1(P_C^{t-1} - P_O^t) & \text{, ако } P_C^{t-1} > P_O^t \\ 0 & \text{, ако } P_C^{t-1} \leq P_O^t \end{cases}. \tag{2.26}$$

Калибрирането на модела се извършва чрез минимизация на целевата функция:

$$J = \sum_{i=1}^{n} \left(\Delta_{OH}^{(i)} - o_{1\text{Max}}^{(i)}\right)^2 + \sum_{i=1}^{n} \left(\Delta_{OL}^{(i)} - o_{2\,\text{Max}}^{(i)}\right)^2. \tag{2.27}$$

Симулационното отгряване се използва за оптимизация, като вероятността за приемане на по-лошо решение се определя от:

$$P(\Delta E) = exp\big(-\frac{\Delta E}{T}\big), \tag{2.28}$$

където T е температурата, а ΔE е разликата в целевата функция. Температурата намалява по функция $T(t) = T_0.\alpha^t$.

Моделът на пропускливия дипол интегрира невробиологични механизми и стохастични оптимизационни техники, като позволява адаптивно прогнозиране на фи-

нансови данни и улавяне на динамиката на пазарните процеси.

2.2.3 Резултати

Регресионният анализ на динамиката на най-високата и най-ниската дневна цена на акциите разкрива, че корелацията с по-стари от пет дни данни е пренебрежимо малка. Това свидетелства за доминиращата роля на краткосрочните фактори и емоционалните реакции на инвеститорите спрямо новините и цените от предходния ден. В този контекст, класическите регресионни модели, както и техните разновидности като хребетна регресия и ласо, не предоставят статистически значими независими променливи, което ги ограничава до функции, напасващи се върху наличните данни. Така като най-надеждни методи за прогнозиране на бъдещи цени се оформят два подхода (1) използването на средната стойност за последните пет дни (*Последни-5*) или (2) цената от предходния ден (*Последни-1*). Тези подходи могат формално да се опишат чрез следните уравнения:

$$\widehat{P}_H^{t+1} = \beta_1 P_O^{t+1} + \beta_2 P_L^t + \beta_3 P_H^t. \tag{2.29}$$

$$\widehat{P}_L^{t+1} = \beta_1 P_O^{t+1} + \beta_2 P_H^t + \beta_3 P_L^t. \tag{2.30}$$

Параметрите β_1, β_2 и β_3 са регресионни коефициенти. Прогнозата от тип *Последни-5* се определя чрез:

$$\widehat{P}_H^{t+1} = \frac{1}{5}\sum_{i=0}^{4} P_H^{t-i} \tag{2.31}$$

$$\widehat{P}_L^{t+1} = \frac{1}{5}\sum_{i=0}^{4} P_L^{t-i}. \tag{2.32}$$

Таблица 2.1: Прогнозиране на най-висока дневна цена за акциите на компания за кино абонаментна услуга

Отн. стат. грешка	Последни-1 (n = 37)	Последни-5 (n = 37)	Регр. анализ (n = 36)	Невронен (n = 37)
Медиана, %	-5.20	-9.33	-2.75	-1.38
Средна ст., %	-4.46	-12.45	-9.84	0.44
Ст. откл., %	11.68	13.38	37.38	7.81
Максимум, %	30.44	47.83	195.82	26.01

Таблица 2.2: Прогнозиране на най-ниска дневна цена за акциите на компания за кино абонаментна услуга

Отн. стат. грешка	Последни-1 (n = 37)	Последни-5 (n = 37)	Регр. анализ (n = 36)	Невронен (n = 37)
Медиана, %	-1.11	-7.37	-0.32	-2.70
Средна ст., %	-4.08	-11.78	-4.66	-4.31
Ст. откл., %	9.13	13.43	23.37	7.15
Максимум, %	33.33	60.00	115.45	19.75

Таблица 2.3: Прогнозиране на най-висока дневна цена за акциите на топ 25 компаниите в индекса NASDAQ-100

Отн. стат. грешка	Последни-1 (n = 37)	Последни-5 (n = 37)	Регр. анализ (n = 36)	Невронен (n = 37)
Медиана, %	-0.15	-0.24	0.17	1.19
Средна ст., %	-0.19	-0.30	0.53	-2.20
Ст. откл., %	1.93	0.87	2.39	4.79
Максимум, %	10.06	2.42	20.30	27.42

Таблица 2.4: Прогнозиране на най-ниска дневна цена за акциите на топ 25 компаниите в индекса NASDAQ-100

Отн. стат. грешка	Последни-1 (n = 37)	Последни-5 (n = 37)	Регр. анализ (n = 36)	Невронен (n = 37)
Медиана, %	-0.09	-0.30	0.20	0.87
Средна ст., %	-0.24	-0.33	0.40	1.52
Ст. откл., %	2.28	1.09	4.44	5.31
Максимум, %	9.72	2.89	60.21	30.96

Таблица 2.5: Резултати от статистически тестове върху абсолютните грешки на регресионния и неронния модел при прогнозиране на NASDAQ-25 акциите (n = 22 дни, m = 25 акции)

Стат. тест	Стат. стойност	P-стойност
Тест за свързани извадки	678.303	0.1462
t-тест на независими извадки	41.764	0.4309
Тест на Ман-Уитни	44.1546	0.0034
Тест на знаковите рангове	23.8689	0.3541
Знаков тест	21.7755	0.4733

Таблици 2.1 и 2.2 показват, че невронният модел прави най-добри прогнози за най-висока и най-ниска цена за деня. Моделът *Последни-1*, използващ само цената от предходния ден, постига сравнима точност с невронния модел, което налага използването на статистически тестове за по-прецизна оценка. Резултатите от статистическите тестове показват, че за прогнозиране на най-висока дневна цена, невронният модел базиран на пропусклив дипол превъзхожда *Последни-1*, потвърдено от теста на Ман-Уитни ($value = 544$, $p = 0.0314$) и теста на Крускал-Уолис ($value = 4.61$, $p = 0.0309$). За най-ниска дневна цена обаче (където динамиките бяха по-стабилни в сравнение с най0висока дневна цена), статистически значими разлики не се откриват.

Таблица 2.4 обобщава резултатите за NASDAQ-25. Макар медианата и средната стойност да са близки до нула за всички методи, стандартното отклонение и максималната грешка потвърждават предимството на невронния модел при прогнозиране на отделни акции, докато при по-ликвидните компании от NASDAQ-100 регресионният модел се представя по-добре или сравнимо. Статистическите тестове, обобщени в таблица 2.5, показват липса на значима разлика между грешките на невронния и регресионния модел, а според теста на Ман-Уитни регресията дори превъзхожда дипола.

В заключение, при акциите на компании с висока ликвидност и професионално управление, каквито са тези от NASDAQ-100, емоционалните фактори имат ограничено влияние върху ценовата динамика, което прави невронните модели по-малко ефективни спрямо класическите регресионни подходи.

2.2.4 Изводи и заключения

Моделът с пропусклив дипол демонстрира отчетливо предимство при прогнозиране на ценови движения на акции в условия на нестабилни и емоционално повлияни пазари, като се адаптира успешно към краткосрочни и емоционални реакции на инвеститорите и постига по-ниски средни и максимални грешки спрямо традиционните линейни регресии; това предимство се проявява най-силно при волатилни активи, където обратната връзка позволява на модела да улавя и използва "емоционални следи"от последните търговски тенденции, докато при стабилни и ликвидни компании от типа на NASDAQ-100, където доминират алгоритмичната търговия и

институционалният контрол, невронният модел не превъзхожда класическите статистически подходи, а перспективите за развитие включват интеграция с допълнителни пазарни индикатори и по-сложни невронни архитектури за подобряване на дългосрочната памет и адаптация към различни пазарни режими.

2.3 Макроикономическо прогнозиране с недостатъчни данни

2.3.1 Прогнозиране на макроикономически индикатори

Прогнозирането на макроикономическите индикатори на Черна гора чрез пропусклив дипол се отличава с опростяване на модела спрямо този, използван за финансови данни, като се елиминират дългосрочната памет и обратните връзки между невроните, за да се улови по-ефективно динамиката на ограничени и оскъдни данни. В тази задача целта е да се прогнозира макроикономическият индикатор на инвестициите в страната като елемент от БВП.В основата на модела стои допускането, че инвестициите зависят както от компоненти на БВП, така и от външни икономически и геополитически фактори. Това се формализира чрез следните уравнения:

$$\dot{x_1} = -x_1 + I_{base} + I_{\Delta^+} + \delta_1 I_{NATO/EU} \tag{2.33}$$

$$\dot{x_2} = -x_2 + I_{base} + I_{\Delta^-} + \delta_2 I_{CRISES} \tag{2.34}$$

Тук x_1 и x_2 са неврони, които получават и предават входни данни, а I_{Δ^+} и I_{Δ^-} са положителните и отрицателните компоненти на БВП. Външните ефекти $I_{NATO/EU}$ и I_{CRISES} моделират съответно позитивни и негативни шокове. Конкретно в този случай тези сигнали играят ролята на екзогенни шокове, но по същият начин към диполния модел мога да бъдат включени сигнали за ненаблюдавани (латентни) променливи, стохастични смущения, и влиянието на несъвършена информация върху прогнозите. Константите δ_1 и δ_2 мащабират тяхното влияние.

Мрежата използва невроните x_1, x_2, y_1, y_2, x_3, x_4 и x_5, като y_1 и y_2 обхващат положителните и отрицателните аспекти на вътрешната динамика, а x_5 обобщава всички ефекти и прогнозира годишната промяна на инвестициите. Динамиката на

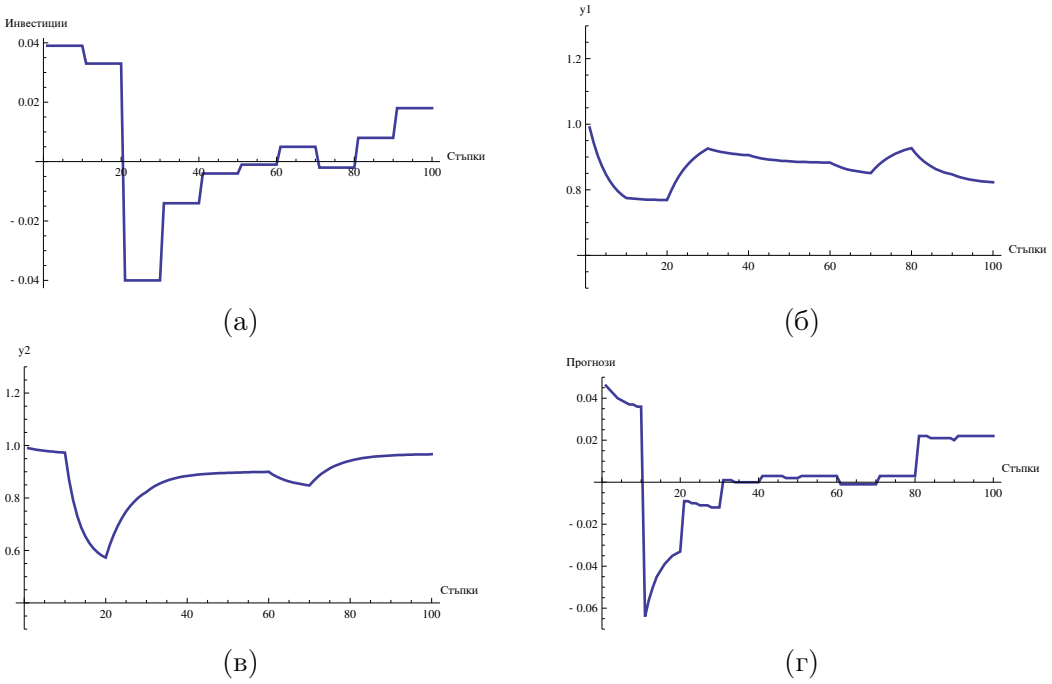

Фигура 2.3: Сигнали през невроните на пропускливия дипол със скалирани стойности на зависимата променлива (а) Скалиране и трансформиране на стойносите на икономическата променлива. (б) Променливата y_1 приема сигнал. (в) Променливата y_2 приема сигнал. (г) Прогнозиране. По абсцисите са отразени дискретни изчислителни стъпки, а по ординатите са безразмерни величини.

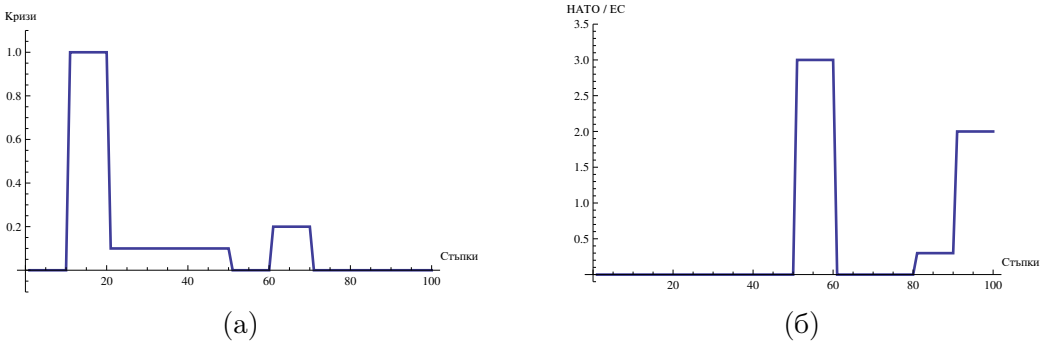

Фигура 2.4: Позитивни и отрицателни шокови въздействия върху икономиката (а) Глобална икономическа криза последвана от локална политическа криза в страната (b) Приемане като член на НАТО и начало на преговори за присъединяване към Европейски съюз. По абсцисите са отразени дискретни изчислителни стъпки, По ординатите стойносите са безразмерна единица.

тези процеси е илюстрирана на фиг.2.3, където се проследява скалирането на икономическите променливи, реакцията на невроните и прогнозата за инвестициите. Аналитичното решение за y_i е дадено от:

$$y_i(t) = y_i(t-1)e^{(-c_i x_i(t)-b_i)} + \frac{b_i}{b_i + c_i x_i(t)} \left[1 - e^{(-c_i x_i(t)-b_i)}\right] \tag{2.35}$$

където $i = [1, 2]$ и $t = [1, 10]$ е дискретното време. Прогнозираната промяна на инвестициите се изразява чрез:

$$G(t) = \alpha x_5(10t), \tag{2.36}$$

където $G(t)$ е прогнозата за година t, а α мащабира сигнала към макроикономическата променлива.

Моделът позволява обучение от единични прогнозни точки, като всяка нова година се използва за калибриране и подобряване на прогнозата, което е аналогично на решаване на задача на Коши с начално условие. Този подход осигурява адаптивност и устойчивост на модела при ограничени данни и динамично променяща се икономическа среда.

В заключение, пропускливият дипол се отличава с адаптивно осцилиращо свойство, което позволява да се моделират както динамичните емоции в мозъка, така и колебанията на икономическите показатели под влияние на вътрешни и външни фактори. Влиянието на позитивни и негативни шокове върху икономиката е илюстрирано на фиг.2.4а и 2.4б, където се разглеждат ефектите от глобални и локални кризи, както и от интеграционни процеси като членство в НАТО и ЕС.

2.3.2 Резултати

Сравнението между линейния регресионен модел и модела на пропусклив дипол при прогнозиране на макроикономически показатели за Черна гора показва ясно предимство на невронния подход. При анализ на данни за БВП, инвестиции и потребление, невронният модел демонстрира по-висока точност и по-добра адаптивност към променящите се икономически условия. Използвани са различни комбинации от входни променливи и метод с разширяващ се времеви прозорец. Резултатите, проверени с непараметричния тест на Уилкоксън, показват превес на невронния модел в повечето случаи (таблица 2.6). Това потвърждава неговата способност да

Таблица 2.6: Резултати от тест на Уилкоксън между неврония и линейния модел

БВП

	2010	2011	2012	2013
Черна гора	9261.0 (2.13 E-9)	1926.0 (2.78 E-34)	551.0 (8.41 E-41)	7364.0 (3.04 E-14)
Германия	5157.0 (2.84 E-21)	269.0 (3.28 E-42)	1555.0 (5.52 E-36)	141.0 (7.37 E-43)
Франция	137.0 (7.03 E-43)	133.0 (6.71 E-43)	1957.0 (3.83 E-34)	344.0 (7.81 E-42)

Инвестиции

	2010	2011	2012	2013
Черна гора	15897.0 (0.7197)	14228.0 (0.0760)	3260.0 (1.61 E-28)	1748.0 (4.29 E-35)
Германия	11441.0 (3.50 E-5)	4346.0 (3.10 E-24)	940.0 (6.74 E-39)	676.0 (3.48 E-40)
Франция	280.0 (3.72 E-42)	1069.0 (2.82 E-38)	102.0 (4.67 E-43)	1464.0 (2.08 E-36)

Потребление

	2010	2011	2012	2013
Черна гора	8101.0 (3.14 E-12)	1115.0 (4.67 E-38)	657.0 (2.81 E-40)	6360 (2.96 E-17)
Германия	1366.0 (7.24 E-37)	8859.0 (2.48 E-10)	5225.0 (4.92 E-21)	2045.0 (9.55 E-34)
Франция	10331.0 (3.78 E-7)	10618.0 (1.32 E-6)	6620.0 (1.91 E-16)	11692.0 (8.65 E-5)

Невронният модел постига по-точна прогноза.
Линейният модел постига по-точна прогноза.
☐ Двата модела постигат еднакво точни прогнози.

улавя по-сложни, нелинейни зависимости в условия на икономическа неопределеност и ограничена информация за прогнозиране..

2.3.3 Изводи и заключения

Диполният модел въвежда иновативен подход за прогнозиране на макроикономически показатели в малки и отворени икономики като Черна гора, където класическите иконометрични методи са ограничени от недостатъчни данни и непредвидими външни шокове. Използването на адаптивни невронни модели за макроикономическо прогнозиране позволява бързо адаптиране към нови данни и смени в техния режим причинени от непредвидими екзогенни фактори.

Еднин от изводите в тази част на изследването е че успешното прогнозиране на макроикономическият показател за инвестициите макар и успешно е резултат от бързата адаптация на невронния модел към нови данни след смяна на режима им.

2.4 Прогнозиране на икономиките на Европейски Съюз в условия на икономическа нестабилност

2.4.1 Точност на макроикономическите прогнози на Европейски съюз

Европейската комисия публикува тримесечни прогнози за макроикономическите показатели на страните от ЕС-27, като за всеки индикатор се анализират осреднените прогнозни грешки и стандартните отклонения за всички държави. На фиг.2.5 са представени динамиките на тези грешки за четири ключови макроикономически показателя: Брутен вътрешен продукт, крайно потребление на домакинствата и НКОД, износ и внос на стоки и услуги. Графиките ясно илюстрират, че както средната грешка, така и стандартното отклонение се увеличават значително в периоди на икономически кризи — финансовата криза през 2008, дълговата криза в Гърция 2014–2015 и пандемията през 2020. Въпреки тези предизвикателства, моделите на ЕК демонстрират относително висока точност, но най-големи трудности се наблюдават при прогнозиране на показателите за внос и износ на стоки и услуги, където нестабилността на международната търговия води до по-големи отклонения. Този извод подчертава необходимостта от усъвършенстване на моделите именно в областта на външнотърговските прогнози.

2.4.2 Прогнозиране на макроикономически индикатори

В настоящото изследване се анализират възможностите на пропускливия дипол да прогнозира макроикономически индикатори на 27-те държави от ЕС, като се използва значително по-широк набор от данни и по-дълъг времеви хоризонт спрямо предходните анализи за Черна гора. Основният изследователски въпрос е оценяването способността на модела да прогнозира измененията на макроикономическите показатели в условия на хронична нестабилност, породена от глобални фактори като пандемия, война, енергийна криза и нарушени вериги за доставки. Моделът е калибриран чрез метода на симулационното отгряване, а входните данни са нормализирани за елиминиране на мащабни различия между индикаторите.

Ефективността на модела е тествана в три ключови периода: преди финансовата

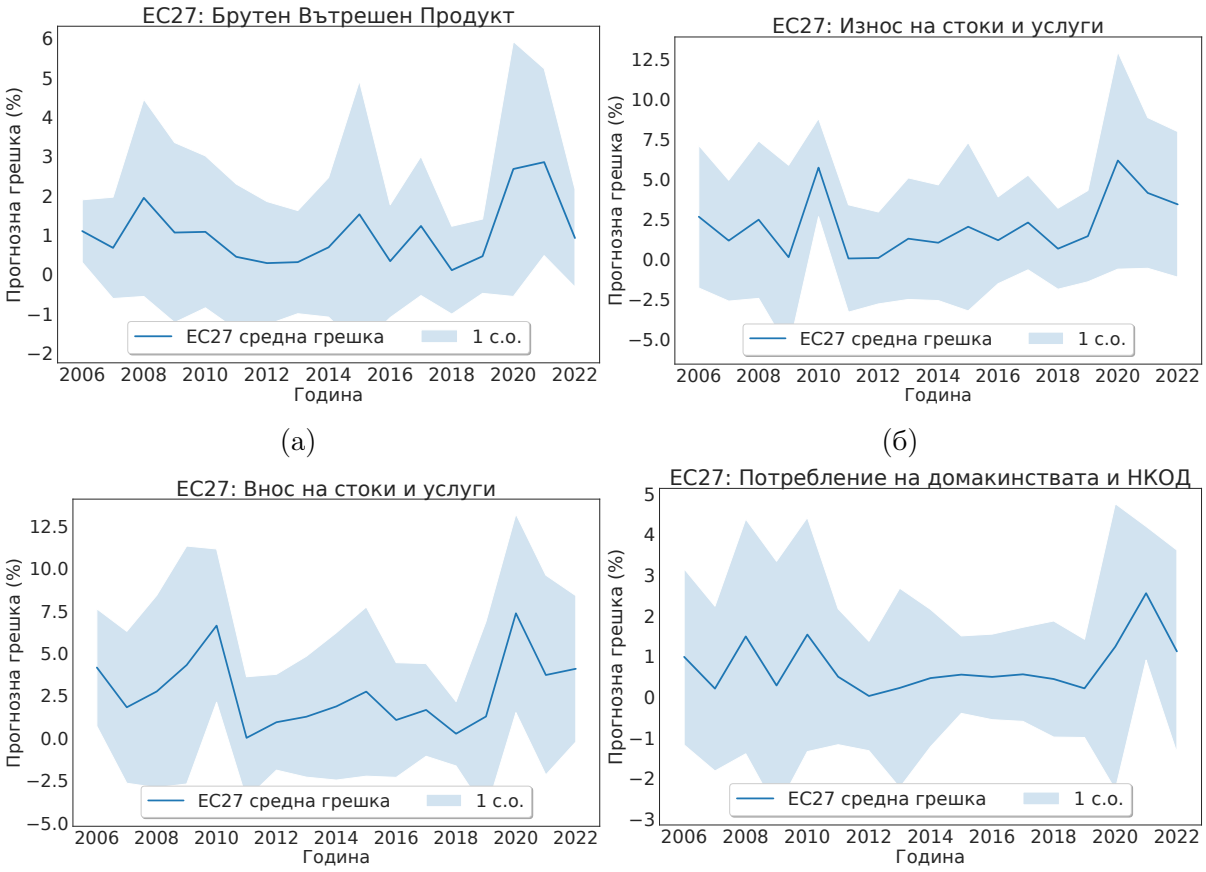

Фигура 2.5: Осреднена прогнозна грешка за някои основни макроикономически показатели на ЕС-27 (а) Брутен Вътрешен Продукт (б) Крайно потребление на домакинствата и некомерсиалните организации с цел обслужване на домакинства (НКОД) (в) Износ на стоки и услуги (г) Внос на стоки и услуги. По абсцисите са отразени години. По ординатите е дадена осреднената грешка за всички държави в ЕС-27, а полето около линията показва едно стандартно отклонение за грешката. Източник на данните (от 2023): `https://economy-finance.ec.europa.eu/economic-forecast-and-surveys/economic-forecasts_en`

криза (2005–2009), по време на възстановяването от финансовата криза (2008–2013) и в условията на COVID-19 пандемията (2018–2022). Диполният модел прогнозира макроикономическите показатели на всяка държава от ЕС-27, като за всяка година се използват шест макроикономически променливи, една от които е зависима, а останалите — независими, включително и авторегресия. За всяка комбинация от независими променливи се изчислява средната абсолютна процентна грешка (MAPE), което позволява сравнение с прогнозите на Европейската комисия.

В това изследване от диполния модел са премахнати синтетичните входни сигнали за екзогенни шокове и са използвани само макроикономически показатели на съответните държави. Диференциалните уравнения за невроните x_1 и x_2 са форму-

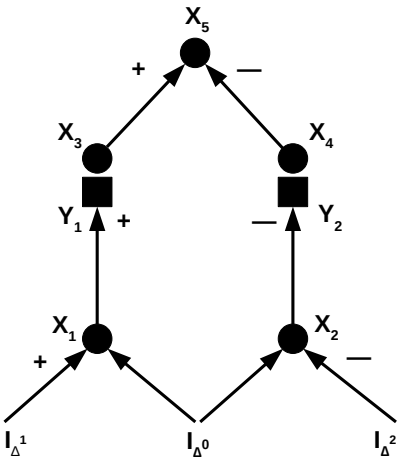

Фигура 2.6: Схема на пропускливия дипол, използван за прогнозиране на макроикономическите индикатори на ЕС-27

лирани по следния начин:

$$\dot{x}_i = -x_i + I_b + I_{\Delta^i}, \tag{2.37}$$

за $i \in \{1, 2\}$.

Останалите неврони се описват с вече разгледаните уравнения: y_1 и y_2 с 2.9 и 2.10, x_3 и x_4 с 2.13 и 2.14, а изходният неврон x_5 с 2.15. Входният сигнал I_b поставя системата в работно състояние, а $I_{\Delta^1}, I_{\Delta^2}$ са свързани със стимули от средата. y_1, y_2 изпълняват ролята на средносрочна памет, а цялата система от диференциални уравнения се решава с помощта на аналитични методи.

2.4.3 Резултати

В анализа на прогнозните способности на невронния модел и моделите на Европейската комисия (ЕК) за макроикономическите показатели на страните от ЕС-27 през 2019–2022 се открояват съществени разлики, особено в условията на глобални шокове като COVID-19 пандемията и война в Украйна. През 2020 г. невронният модел показва по-висока точност при прогнозиране на "износ на стоки и услуги"за 12 държави и на "внос на стоки и услуги"за 13 държави, докато през останалите

години ЕК доминира по точност. Таблици 2.7 и 2.8 представят сравнителните резултати за относителните грешки на двата подхода, като се отчита, че невронният модел се адаптира бързо на неочаквани събития, но също така бързо нормализира прогнозите си при стабилизиране на средата.

В анализа на резултатите трябва да се отчете, че невронният модел работи само с показатели на съответната държава, без да използва данни от други страни, което ограничава възможността за улавяне на междудържавни корелации, които са взети под внимание в моделите на ЕК. Най-голям потенциал за невронния модел се наблюдава при прогнозиране на "внос"и "износ на стоки и услуги тъй като тези показатели са силно чувствителни към реактивни фактори като инфлация, лихвени проценти и промени в митата. За разлика от войната в Украйна, COVID-19 пандемията оказва глобално и непредсказуемо въздействие, което води до по-големи отклонения в прогнозите. На фиг.2.7 е илюстрирана динамиката на осредната прогнозна грешка за основните макроикономически показатели на ЕС-27, като се вижда, че невронният модел реагира по-силно на шокови събития, но бързо се адаптира при нормализиране на средата.

2.4.4 Изводи и заключения

Резултатите от експериментите показват, че невронният модел проявява висока адаптивност и по-добра точност при прогнозиране на износа и вноса на стоки и услуги в условия на внезапни и глобални шокове. Такъв пример е кризата с COVID-19 през 2020 г. В по-стабилна макроикономическа среда обаче моделите на Европейската комисия постигат по-добри резултати. Това се дължи на по-обширната им информационна база и способността им да отчитат междудържавни зависимости и вече настъпили ефекти.

Фигура 2.7 илюстрира динамиката на прогнозните грешки, като ясно се вижда по-бързата реакция на невронния модел при шокови събития и последващата нормализация. Тези резултати потвърждават потенциала на невробиологичните модели като допълващ инструмент в макроикономическото прогнозиране, особено при екзогенни сътресения.

Наблюденията подчертават необходимостта от интегриране на допълнителни индикатори и разработване на хибридни подходи, които да повишат устойчивостта и

ЕС-27 държава	Износ на стоки и услуги				Внос на стоки и услуги			
	2019		2020		2019		2020	
	НМ	ЕК	НМ	ЕК	НМ	ЕК	НМ	ЕК
Австрия	1.85	0.14	13.38	2.77	1.58	0.44	14.90	1.34
Белгия	1.20	1.96	7.90	6.27	0.70	2.12	8.18	6.18
България	7.47	0.55	6.58	2.21	3.79	0.16	4.84	6.28
Германия	1.31	0.01	14.04	3.07	1.28	0.02	13.45	0.67
Гърция	3.14	0.14	13.39	0.35	2.95	2.67	14.54	12.00
Дания	2.43	2.41	3.14	3.97	2.49	0.73	3.26	4.92
Естония	3.19	2.89	2.75	7.92	2.88	0.10	2.20	11.56
Ирландия	20.20	5.36	3.70	22.56	37.04	26.16	21.88	21.89
Испания	2.55	0.17	30.31	0.43	1.57	1.48	37.71	6.96
Италия	1.20	0.27	25.13	0.88	2.38	2.87	30.24	1.15
Кипър	3.06	1.21	8.16	10.74	1.49	1.52	5.68	11.49
Латвия	1.81	0.09	4.19	7.79	2.13	0.93	2.92	5.21
Литва	3.99	5.37	3.03	12.49	3.88	1.73	1.66	7.06
Люксембург	0.97	0.96	0.75	13.63	2.06	0.88	0.99	13.85
Малта	8.47	3.18	3.11	3.20	9.00	3.38	3.18	4.60
Нидерландия	1.38	0.37	6.01	6.06	1.46	1.29	5.85	6.00
Полша	2.76	0.01	2.60	9.62	2.58	2.57	2.68	8.90
Португалия	3.70	0.72	17.11	5.59	2.93	0.17	15.41	1.81
Румъния	7.09	0.18	7.04	3.42	3.79	0.05	4.78	9.77
Словакия	1.62	5.27	11.99	5.28	1.54	3.05	11.40	4.65
Словения	2.22	0.84	7.52	4.09	2.22	1.46	8.57	2.01
Унгария	5.34	1.14	2.94	7.73	4.46	1.31	3.15	11.06
Финландия	2.91	3.40	5.91	4.21	2.87	0.11	9.79	2.24
Франция	1.65	1.16	25.20	4.53	2.03	0.15	24.91	0.07
Хърватска	7.19	3.37	15.89	5.39	3.52	0.98	15.39	8.59
Чехия	0.94	1.79	8.79	6.85	1.76	2.61	9.45	6.59
Швеция	2.65	2.71	3.87	7.73	3.01	0.22	7.93	6.20
НМ:ЕК	6:21		12:15		5:22		13:14	

Таблица 2.7: Сравнение на относителните грешки в прогнозите на невронния модел (НМ) и моделите на Европейската Комисия (ЕК). Числата са в %. Данни на ЕК от 2021 година

ЕС-27 държава	Износ на стоки и услуги				Внос на стоки и услуги			
	2021		2022		2021		2022	
	НМ	ЕК	НМ	ЕК	НМ	ЕК	НМ	ЕК
Австрия	29.04	1.49	5.42	4.40	28.23	5.36	5.32	3.04
Белгия	19.23	4.82	4.02	1.68	20.03	4.13	3.42	1.25
България	31.59	3.61	5.65	3.48	22.22	4.46	4.90	5.00
Германия	20.33	0.67	3.13	0.88	20.61	0.90	2.54	2.38
Гърция	62.89	12.09	7.27	6.41	36.14	9.65	6.58	2.10
Дания	18.14	2.11	4.08	4.91	16.20	2.96	4.22	1.41
Естония	31.03	13.61	10.40	0.01	23.76	18.85	11.49	3.68
Ирландия	4.70	7.21	6.44	6.95	10.64	16.44	33.87	8.37
Испания	47.12	2.73	5.86	1.35	41.30	2.80	5.55	1.23
Италия	40.53	3.09	6.30	4.58	40.59	3.16	6.20	5.64
Кипър	11.36	13.43	12.11	10.49	10.15	10.11	16.32	13.34
Латвия	21.52	2.33	8.89	8.17	19.97	4.22	5.48	7.11
Литва	22.17	9.01	4.24	12.74	29.49	10.03	5.56	11.85
Люксембург	11.01	6.60	8.36	4.47	13.76	8.34	10.04	6.33
Малта	8.71	2.16	5.88	1.18	5.37	0.97	8.87	3.69
Нидерландия	11.13	1.44	2.33	0.58	12.44	0.33	3.55	0.25
Полша	22.74	3.15	3.60	1.16	25.24	5.98	4.05	1.02
Португалия	44.82	1.80	10.39	4.34	32.85	2.44	8.66	2.21
Румъния	34.65	2.49	6.21	4.61	25.07	3.08	4.35	4.46
Словакия	19.81	1.56	5.94	0.09	22.90	0.75	6.88	0.81
Словения	30.10	4.35	4.33	2.11	33.65	6.78	5.00	4.31
Унгария	17.79	1.87	6.64	6.84	15.42	1.74	7.27	6.99
Финландия	19.00	0.67	4.90	1.53	16.85	0.11	4.59	5.15
Франция	40.95	0.93	5.92	1.11	33.36	1.64	5.35	1.71
Хърватска	66.33	14.71	12.15	13.55	44.91	5.59	16.45	13.51
Чехия	23.26	1.50	2.54	5.60	24.66	4.34	3.39	4.78
Швеция	21.51	2.99	3.66	2.69	23.82	4.28	3.70	4.38
НМ:ЕК	2:25		6:21		1:26		7:20	

Таблица 2.8: Сравнение на относителните грешки в прогнозите на неврония модел (НМ) и моделите на Европейската Комисия (ЕК). Числата са в %. Данни на ЕК от 2023

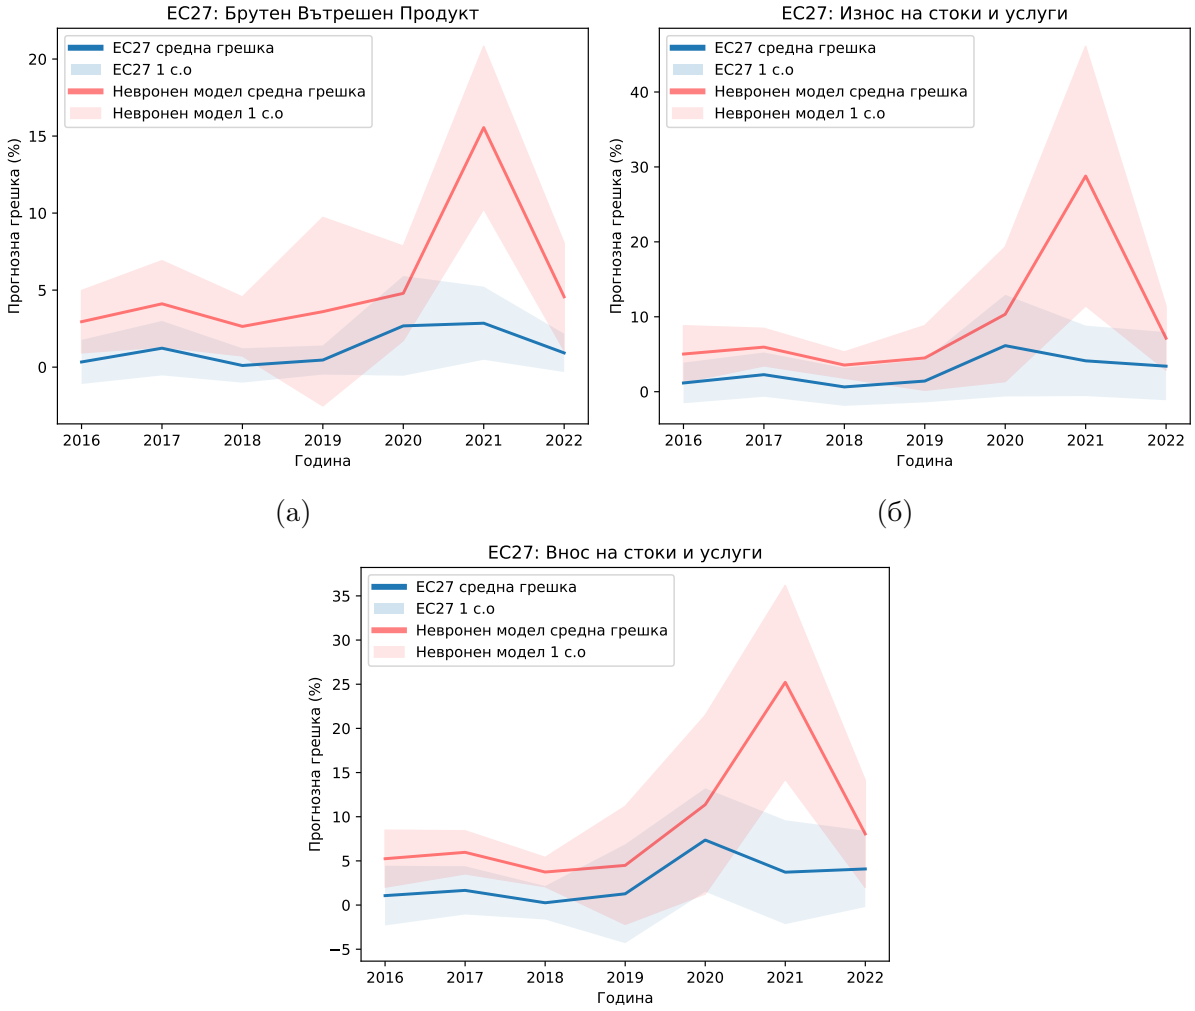

Фигура 2.7: Осреднена прогнозна грешка за някои основни макроикономически показатели на ЕС-27 (а) Брутен вътрешен продукт (б) Износ на стоки и услуги (в) Внос на стоки и услуги. По абсцисите са отразени години. По ординатите е дадена осреднената грешка за всички държави в ЕС-27, а полето около линията показва едно стандартно отклонение (1 с.о.) за грешката. Източник: `https://economy-finance.ec.europa.eu/economic-forecast-and-surveys/economic-forecasts_en`

точността на прогнозите в дългосрочен план.

Заключение

Дисертационният труд изследва възможността за пренос на принципи от математическата невронаука в областта на икономическото прогнозиране чрез прилагането на диполни невронни модели. Експериментите, проведени с данни от нестабилни пазари и с макроикономически данни с ограничена достъпност, показват, че моделът притежава значителен прогностичен потенциал, особено в условия на висока неопределеност и информационен дефицит, където традиционните иконометрични методи често се затрудняват.

В същото време изследването очертава и ограниченията на този подход. В стабилна среда с богата информация предимството на невронния модел отслабва. Тези изводи са потвърдени чрез сравнение с официални прогнози, включително точността на прогнозите на Европейската комисия спрямо реално отчетените макроикономически показатели на страните от ЕС-27.

Като цяло, дисертацията допринася както с разработката и тестването на конкретен диполен модел, така и с демонстрацията, че концепции от математическата невронаука могат успешно да бъдат адаптирани за прогнозиране на икономически данни. Това отваря перспективи за бъдещи хибридни подходи, в които класическите иконометрични техники се допълват от гъвкави, адаптивни невронни системи.

Научни и научноприложни приноси

В хода на дисертационното изследване са постигнати следните основни научни и научноприложни резултати:

Първо, е демонстрирано, че диполният невронен модел превъзхожда класическите линейни авторегресионни подходи при прогнозиране на цените на акции в ситуации на краткосрочна пазарна нестабилност и наличие на екстремни стойности. В същото време са отчетени ограничения в ефективността на модела при прогнозиране на стабилни и високоликвидни активи.

На второ място, моделът е приложен успешно за прогнозиране на макроикономически индикатори на малка и отворена икономика (Черна гора), в периоди на политически и икономически кризи и недостатъчни макроикономически данни за директно прилагане на стандартни иконометрични модели. Въпреки това с неврон-

ния модел са постигнати по-точни прогнози спрямо тези, получени чрез класически иконометрични методи.

На трето място, в условия на краткосрочна глобална икономическа криза – икономическият спад през 2020 в следствие на COVID-19 пандемията – диполният модел показва по-добра прогностична точност от линейните авторегресионни модели при макроикономическите показатели на страните от ЕС-27. Същевременно е идентифицирано, че при по-продължителни и предвидими кризи, като тази през 2022 г. (вследствие на войната в Украйна), предимствата на невронния модел намаляват.

Освен това, в дисертацията са изследвани границите на приложимост на модела. Установено е, че неговата адаптивност се проявява най-силно при прогнозиране на времеви редици с ограничена налична информация и с чести, случайни смени на режима – например при силно волатилни финансови данни или икономически показатели, чувствителни към външни шокове, като „внос“ и „износ на стоки и услуги“.

Накрая, е показано, че диполният невронен модел може да бъде използван като част от системи за ранно предупреждение, които комбинират невронно самообучение с реални икономически данни – посока с потенциал за практическо приложение в макроикономическия анализ и икономическата политика.

Списък на публикациите по темата на дисертацията

По темата на дисертацията са направени 7 публикации, от които шест са реферирани и индексирани в базата данни Scopus и/или Web of Science.

Отделни части от научните разработки описани в настоящата дисертация са представени като междинни вътрешни технически доклади в Hasso Platner Institute (Потсдам, Германия), който по линията на международен научен проект, предостави изчислителните ресурси за експериментите описани в глава 3 и глава 4.

№	Публикация	Индекс
1	G. Mengov, **I. Nenov**, et al. *Neurocomputational Forecasting of Economic Shocks*. 2024 IEEE 14th Int. Conf. on Intelligent Systems.	Scopus
2	**I. Nenov**, R. Simeonova-Ganeva, et al. *A Neural Model Forecasts Macroeconomic Indicators*. 2023 Int. Conf. Automatics and Informatics (ICAI).	Scopus
3	**I. Nenov**, *Software-defined Wide-area Networks in the Coevolution of Network and Computational Bandwidth*, C. R. Acad. Bulg. Sci., 75(12), 2022.	Scopus, WoS
4	**I. Nenov**, G. Mengov, et al. *Neurocomputational economic forecasting with a handful of data*. Technical report, 2021.	Scopus, WoS
5	G. Mengov and **I. Nenov**. *Towards an intelligent neural system for economic and business forecasting*. 2020 IEEE 10th Int. Conf. on Intelligent Systems.	Scopus
6	G. Mengov, **I. Nenov**, and I. Zinovieva. *A model for collective emotion forecasts financial data*. IFAC-PapersOnLine. 2019.	Scopus, WoS
7	G. Mengov and **I. Nenov**. *Прогнозиране на финансови времеви редове с невронни мрежи....* Сборник от межд. конф. на УНСС и СУ, 2018.	-

Списък на публикациите, свързани с дисертацията

Общ брой точки: 82.5 от минимално изисквани 30 точки за придобиване на ОНС „Доктор“ по Научна област 3. Социални, стопански и правни науки, Професионално направление 3.8. Икономика.

Понастоящем четири от статиите по темата на дисертацията са цитирани в публикации, които са индексирани в бази данни с научна информация *Scopus* и **Web of Science**, както следва:

Статия №2 е цитирана в научна статия индексирана в Scopus и WoS

- Jabbari, A., Azizi, J. (2024). *The Role of Artificial Intelligence in Macroeconomics*. Available at SSRN 4854582.

Статия №4 е цитирана в глава от книга

- George, M. L. *AN ELABORATION OF THE ECONOMIC FORECASTING*. Managing Investment Portfolios, 141.

Статия №5 е цитирана в научни статии индексирани в Scopus и WoS

- Liu, E., Zhu, H., Liu, Q., Udimal, T. B. (2022). *Regional Economic Forecasting Method Based on Recurrent Neural Network*. Mathematical Problems in Engineering, 2022.

- Yaqoob, I.A.M., Kasmiran, K.A., Aris, T.N.M., Husin, N.A., Sharum, M.Y.(2023). *Improving Cash Forecasting Performance Using A new Hybrid-ANN-ARIMA-EM model*. Journal of Theoretical and Applied Information Technology, 101(18)

Статия №6 в цитирана в научна статия индексирана в Scopus и WoS

- Liu, B., Du, M., Zhou, H. (2021, October). *Design of Financial Data Feature Forecast System Based on Clustering Algorithm*. In 2021 3rd International Conference on Artificial Intelligence and Advanced Manufacture (AIAM) (pp. 575-578). IEEE.

Благодарности

Желая да изразя своята искрена благодарност на моя научен ръководител проф. д–р Георги Менгов за безценните съвети, подкрепа и мотивация, които ми оказа през целия изследователски процес.

Благодаря сърдечно и на моите колеги от Софийски университет „Св. Климент Охридски“ – доц. д-р Калоян Ганев, доц. д-р Ралица Симеонова-Ганева и проф. д.пс.н. Ирина Зиновиева – за сътрудничеството, насоките и вдъхновението, които ми оказаха в различни етапи от работата.

Благодаря на моето семейство и приятели за тяхната подкрепа и търпение през целия период на изследователската работа. Без тяхната любов и разбиране този труд нямаше да бъде възможен.