



**БЪЛГАРСКА АКАДЕМИЯ НА НАУКИТЕ
ИНСТИТУТ ПО ИНФОРМАЦИОННИ И
КОМУНИКАЦИОННИ ТЕХНОЛОГИИ**

Веселин Лазаров Шахпазов

**ИЗСЛЕДВАНЕ НА МОДЕЛИ
ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИТЕ ПАЗАРИ С
НЕВРОННИ МРЕЖИ**

Дисертация

**ЗА ПРИСЪЖДАНЕ НА ОБРАЗОВАТЕЛНА И НАУЧНА
СТЕПЕН „ДОКТОР“**

**НАУЧНА ОБЛАСТ: 4. ПРИРОДНИ НАУКИ, „МАТЕМАТИКА
И ИНФОРМАТИКА“
ПРОФЕСИОНАЛНО НАПРАВЛЕНИЕ 4.6. „ИНФОРМАТИКА
И КОМПЮТЪРНИ НАУКИ“**

ДОКТОРСКА ПРОГРАМА „ИНФОРМАТИКА“

НАУЧЕН РЪКОВОДИТЕЛ: АКАД. ИВАН ПОПЧЕВ

СЪДЪРЖАНИЕ

УВОД.....	6
ГЛАВА I: МОДЕЛИ ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИТЕ ПАЗАРИ.....	11
1. Прогнозиране на капиталовите пазари.....	11
1.1. Традиционните аналитични методи, използвани за прогнозиране на капиталовите пазари.....	13
1.1.1. Фундаментален анализ.....	13
1.1.2. Технически анализ.....	14
1.1.3. Прогнозиране чрез динамични редове от данни.....	15
1.1.4. Хипотезата за ефективния пазар.....	16
1.1.5. Теория на Хаоса.....	17
1.1.6. Други техники.....	17
1.1.7. Кратко обобщение на традиционните методи за прогнозиране.....	18
1.2. Прогнозиране на капиталовите пазари – общи положения.....	19
1.3. Изкуствен интелект.....	21
1.3.1. Изкуствена невронна мрежа.....	24
1.4. Периоди в развитието на изкуствени невронни мрежи.....	26
1.4.1. Опити за прогнозиране на капиталовите пазари с невронни мрежи.....	29

1.5. Методи за прогнозиране на капиталовите пазари с подходи от изкуствения интелект.....	31
---	----

ГЛАВА II: АНАЛИЗ НА МЕТОДИТЕ ОСНОВАНИ НА НЕВРОННИ МРЕЖИ ЗА ПРОГНОЗИРАНЕ И КАПИТАЛОВИТЕ ПАЗАРИ.....35

2. Характеристики на невронната мрежа.....	35
2.1 Невродинамика.....	37
2.2 Обучение на изкуствена невронна мрежа.....	43
2.3 Организации на невронни мрежи.....	46
2.4 Определяне броя на невроните и скритите слоеве.....	48
2.5 Накратко за характеристиките на невронната мрежа.....	50
2.6 Многослоен Перцептрон.....	51
2.6.1 Обучаващи алгоритми.....	51
2.6.2 Делта правилото / Метод на най-малките квадрати Least Mean Squares (LMS).....	52
2.6.3 Обратното разпространение на грешката / Генерализираното Делта Правило.....	53
2.6.4 Продуктивност на изкуствените невронни мрежи.....	56
2.7 Използване на невронни мрежи за прогнозиране на капиталовите пазари.....	56
2.7.1 Невронните мрежи и прогнозирането на капиталови пазари през годините.....	57
2.7.2 Анализ на резултатите от разгледаните трудове.....	58

ГЛАВА III: РЕЗУЛТАТИ ОТ ИЗСЛЕДВАНЕТО НА МОДЕЛИ ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИ ПАЗАРИ С НЕВРОННИ МРЕЖИ И РАЗРАБОТВАНЕ НА ХИБРИДЕН МОДЕЛ ОТ НЕВРОННИ МРЕЖИ И СИСТЕМИ ОСНОВАНИ НА ПРАВИЛА ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИЯ ПАЗАР.....84

3 Български фондов пазар.....84

3.1 Пазари на БФБ-София.....87

3.1.1 Основен пазар на Българска Фондова Борса.....87

3.1.2 Алтернативен пазар на Българска Фондова Борса.....87

3.1.3 Финансови инструменти на БФБ-София.....87

**3.1.4 Финансови инструменти на Основен пазар на БФБ-София
.....88**

3.1.5 Индекси на БФБ.....88

3.2 Задание за прогнозиране.....91

3.2.1 Избор на данни.....92

3.2.2 Избор на архитектура и обучение на невронните мрежи....94

3.2.3 Активираща функция и оценка на грешката.....97

3.2.4 Резултат от първи експеримент.....98

**3.2.5 Експеримент върху два индекса с различни мрежови
архитектури.....103**

3.2.5.1 Невронни мрежи с радиална базова функция.....103

3.2.5.2 Невронни мрежи с обща регресия.....109

3.3 Формулиране на второто изследване.....112

3.3.1 Избор на данни.....113

3.3.2 Прогнозиране на индексите Sofix и BG40 с трите избрани модела.....	114
3.4 Хибриден модел от невронни мрежи и системи основани на правила за прогнозиране на капиталовия пазар: Индекс Sofix на БФБ – София.....	121
3.4.1 Дефиниране на задачата.....	121
3.4.2 Представяне на източниците на информацията, захранващи моделът.....	123
3.4.3 Използвани невронни мрежи и системи основани на правила.....	125
3.4.4 Представяне на хибридният модел.....	126
ГЛАВА IV: НАСОКИ НА БЪДЕЩИ ИЗСЛЕДВАНИЯ.....	129
ГЛАВА V: ЗАКЛЮЧЕНИЕ - РЕЗЮМЕ НА ПОСТИГНАТИТЕ РЕЗУЛТАТИ С ДЕКЛАРАЦИЯ ЗА ОРИГИНАЛНОСТ НА ДИСЕРТАЦИОННИЯ ТРУД.....	130
ГЛАВА VI: ПУБЛИКАЦИИ ПО ТЕМАТА НА ДИСЕРТАЦИЯТА И ЦИТИРАНИЯ.....	135
ГЛАВА VII: УЧАСТИЯ В ПРОЕКТИ.....	137
ГЛАВА VIII: БИБЛИОГРАФИЯ.....	139
БЛАГОДАРНОСТИ.....	148

УВОД

От край време целта на хората е да направят живота си по-лесен. Властващата идея в модерното общество е, че богатството носи комфорт, спокойствие и престиж, поради което преследването му се е превърнало в норма за хората днес. Въпреки многото аспекти за дефиниране на това какво точно представлява богатството - философски и житейски, чисто материалното му изражение, оценено в парични средства остава единственият му всепризнат универсален измерител. Формирането на богатство е основна движеща сила за индивидите, като начините да се постигането му са безброй, вариращи от незаконни и противообществени до етични и дори социално отговорни. Месечните доходи под формата на заплати, ренти и други приходи, заделени като спестявания или насочени като инвестиции в движима и недвижима собственост могат да бъдат разглеждани като само част от начините за постигане на материална обезпеченост. Но за всеки трябва да е ясно, че за образуването, поддържането и увеличаването на активите на хората, ключов момент е част от тези активи да бъдат вложени в разнообразни по вид, структура и деноминация финансови активи. Най-ярко доказателство за това идва във формата на многобройните изследвания за разширяващата се "ножица" между състоянието на най-богатите и бедните в световен мащаб. Както е описано в доклад на Браян Кийли [1] по темата, озаглавен "Неравенство в доходите": "Причината за нарастващото неравенство са комплексни, но сред главните са нарастващото влияние на технологиите върху икономиката и въздействието на глобализацията. Тези фактори също така помагат да се обясни промяната в групите, които се облагодетелстват най-много от икономиката, като баланса не накланя от работническата класа към капитала." Преобладаващо е мнението, че сред основните причини за това е невъзможността и неспособността на хората с ниски доходи да придобиват капиталови активи. Същевременно, достъпа до капиталови активи се улеснява с всяка изминала година, чрез развитието на технологиите и нарастващата популярност на капиталовите пазари като притегателен център, както за търсене и предлагане на капитали, така и за търсещите печалби посредством активна или пасивна търговия инвеститори и спекуланти.

Според данни на Световната банка [2], съотношението на стойността на листнатите на фондовите борси в целия свят компании, отнесена към глобалния брутен вътрешен продукт е в размер на близо 93% към 2018 година, докато през 1980 година то е било едва 31%. Това може да говори за две неща: първо, че пазара към 2018 г. може да бъде считан за надценен, тъй като е общоприето, че подобни стойности на това съотношение би следвало да се считат за високи (теза подкрепена от множество участници на пазара на капиталови инструменти, начело с небезизвестния Уорън Бъфет [3]) и второ, че през последните близо 40 години е налице непрекъснат тренд, все по-голяма част от световното богатство да се преразпределя на пода на фондовите борси. В този контекст, не е никаква изненада, че във времето са правени и продължават да се правят многобройни опити за отгатване на посоката на движение на капиталовите пазари и търгуваните на тях финансови инструменти и са написани толкова много научни трудове за различни начини да се отгатне посоката на движение и бъдещите цени, за да могат направените инвестиции да бъдат успешни.

Във времето са предлагани и използвани различни методи, базирани върху основата на техническия анализ, фундаменталния анализ и на статистическите индикатори с различна успеваемост. Въпреки това, нито една техника или комбинация от техники не е била достатъчно успешна, че да "побеждава пазара" постоянно, като

отгатва неговата посока и магнитута на движенията му. Всичко това е накарало хората да разгледат, усъвършенстват, модифицират и дори преоткриват известните и считани за традиционни техники за прогнозиране на бъдещо движение на цените на финансовите актив, като и да хвърлят огромен ресурс и енергия за адаптиране на нововъзникващи техники за целите на прогнозирането при тяхната поява. Точно такъв е и случаят с Изкуственият интелект и неговите различни техники. Кой знае, може би това е технологията, която да доведе до затварянето на отворилата се „ножица“ в състоянието между най-високата прослойка и останалата част от обществото, като предостави достъпен, удобен и лесен за използване, автоматизиран, неизискващ задълбочени познания за структурата и особеностите на капиталовите пазари начин за облагодетелстване на несравнимо по-широк кръг от индивиди от доказалия се във времето, като най-добър начин за съхранение и увеличение на богатството подход. Възможно ли е в хода на течащата в момента нова индустриална революция, предвиждаща цифровизация на всички активи и икономически агенти, включването им в единната верига на стойността и тяхната интеграция в обща цифрова устойчива система, обусловена от взаимното надграждане и сливане на технологиите и хората, свързаните мобилни устройства, безпрецедентната процесорна мощ, възможностите за съхраняване на данни и достъп до знания, зашеметяващото едновременно вливане на технологични пробиви в области като изкуствения интелект, интернет нещата и много други тази, наглед утопична идея да намери своята реализация? Вероятно повечето от нас изпитват скептицизъм към подобна перспектива и с определена доза основания, но същото може да се каже и за възгледите ни за самия достъп до капиталовите пазари от преди само две десетилетия, когато много малък брой хора са се доближавали до него, а сега това може да бъде направено от джоба и всеки посредством приложения, като Robinhood Markets Inc.[4], представляващо разположена в САЩ компания за финансови услуги, която предлага мобилното приложение за смартфони, което позволява на всеки да инвестира в публични компании и борсово търгувани фондове, листвани на американските фондови борси, без заплащане на комисионни възнаграждения. Може би някой ден с помощта на изкуствения интелект всичко това ще бъде възможно и всеки индивид ще е в състояние да взема по-справедливо участие в преразпределение на глобалният продукт именно по този начин. Този труд ще се опита да обогати знанията и опита в областта, чрез интердисциплинарно обхващане на няколко различни области от капиталовия пазар и изкуствения интелект.

Изкуственият интелект се основава на хипотезата, че основно човешко качество като интелигентността, може да бъде толкова точно описано, че да бъде пресъздадено от машина. В миналото обект на оптимистични или критични спекулации, днес изкуственият интелект е важен елемент на информационните технологии, използван за разрешаване на някои от най-трудните задачи в областта на информатиката. Изследванията в областта на изкуствения интелект са силно специализирани, обособени в няколко подобласти, които често не успяват да взаимодействат ефективно. Може да се обособят две основни школи с различен подход към изкуствения интелект.

Конвенционален изкуствен интелект, към който могат да се включат:

- Експертни системи - програми, които работят по определени правила, обработват голямо количество информация и в резултат извеждат заключение по нея.
- Разсъждение на основата на аналогични случаи (Case-based reasoning).
- Бейсова мрежа.
- Дърво на решенията
- Поведенчески метод: модулен подход на изкуствен интелект, при който системата се разделя на няколко сравнително автономни програмни поведения, които се задействат в зависимост от измененията във външната среда.

Изчислителен изкуствен интелект

- Невронни мрежи: Система с отлични способности за разпознаване.
- Размити системи: методи за разсъждение в условия на неопределеност.
- Еволюционни и Генетични алгоритми: тук се използват понятия, свързани основно с биологията, като популация, мутация и естествен отбор за усъвършенстване на решенията в задачите. Тези изчисления се делят на еволюционни алгоритми, генетически алгоритми и методи на „сборен“ интелект (например, „мравешки“ алгоритъм).
- Обучение с утвърждение: Група от методи за автоматично обучение, отличаващи се със способността си да функционират без необходимост от примерни решения на поставения проблем.

Всеки един от изброените подходи на Изкуствения интелект е бил обект на обширни изследвания с цел изработването на създаване на печеливша стратегия за търговия на капиталовите пазари. Някои от тях с времето дават по-обещаващи резултати от другите, като по този начин се превръщат в т. нар. фаворити на изследователи и инвеститори.

С напредването на технологиите за изчисление и развитието в полето на изкуствените невронните мрежи, научни изследователи и инвеститори се надяват, че ще могат успешно да придобият уменията да разплитат сложните „пазарни възли“ които да им позволят да изградят успешна стратегия за търговия. В този дисертационен труд ще бъдат проучени някои традиционни техники използвани за прогнозиране на пазара на акции и други финансови инструменти, като се акцентира върху това, защо те не са достатъчни за постоянно коректно предвиждане и как невронните мрежи се използват и биха могли да бъдат използвани за подобряването на процеса прогнозиране.

Няма никакво съмнение, че най-голямото предизвикателство пред финансовите професионалисти и научните изследователи е наличието на несигурност и неопределеност. Всъщност рискът, който произтича от несигурността и неопределеността, е от фундаментално значение за съвременната теория на финансите и появата му като отделна научна дисциплина, затова голяма част от интелектуалните ресурси в областта са посветени на анализа на риска. Наличието на риск не само усложнява вземането инвестиционни решения, то създава възможности за и възнаграждава тези, които могат да се анализират и управляват ефективно риска.

Като цяло развитието на технологията на търговия и тази за управление на риска може да се характеризира с това, че компютърна технология постоянно изостава от теоретичните постижения в тези ключови сфери.

Измежду многобройните техники от полето на Изкуствения интелект, тази които най-добре се справят с несигурността са невронните мрежи [5]. Справянето с несигурността в областта на финансите включва основно разпознаване на тенденции в бази данни и използване на тези тенденции, за да се предскажат бъдещи събития. Точното прогнозиране на икономически събития, като например промени в лихвените проценти и движения във валутни курсове се нарежда като едно от най-трудните начинания в областта на финансите, също така се определят, като едни от най-критичните за т.нар. финансово оцеляване. Изкуствените невронни мрежи се справят с тези проблеми по-добре в сравнение с други техники на изкуствения интелект, тъй като работят добре с големи непрецизни бази данни. За разлика от експертните системи, изкуствените невронни мрежи не са толкова прозрачни и резултатите получени, чрез тяхното използване не могат да бъдат толкова лесно обяснени, което ги прави трудни за интерпретиране.

Съществуват множество причини да се желае предсказване на бъдещото движение на цените на активите, търгувани на финансовите пазари. Първата и най-важна е реализирането на печалба! Всяка система, която може постоянно да идентифицира печелившите и губещите акции, търгувани на фондовите борси, във все по-динамичните и сложни пазарни условия, ще бъде в състояние да направи своя притежател много богат. Поради тази причина много хора, включително изследователи, инвестиционни професионалисти, и обикновенните инвеститори непрекъснато са в търсене на тази система, която ще им донесе по-висока възвръщаемост на инвестициите. Тъй като това начинание е непостижимо за огромната част от експериментите в областта, втората най-разпространена причина за провеждането на изследвания в областта е свързана с небезизвестната „Хипотеза за ефективния пазар”. Разработена от Професор Юджийн Фама [6] в края на 60-те години на 20-ти век, тя намира множество поддръжници и критици. Според него акциите се търгуват винаги по справедливата си стойност, което прави невъзможно инвеститорите да купуват подценени акции или да продават акции за завишени цени. Поради тази причина би следвало да не е възможно да се постигне по-висока доходност от тази на общия пазар посредством експертен подбор на акции или преценка за момента на покупка или продажба и единственият начин, по който инвеститорът може да получи по-висока доходност от тази на широкия пазар, е случайно или чрез закупуване на по-рискови инвестиции. Съществуват три варианта на хипотезата: "слаба", "полусилна" и "силна" форма.

Хипотезата за ефективните пазари посочва, че нито една система не може непрекъснато да се представя по-добре от общия пазар на акции, защото ако тази система стане публична, всеки ще започне да я използва, като по този начин се елиминира потенциала и за печалба. По темата постоянно се дебатира, а валидността и се поставя на множество тестове. Някои изследователи се опитват да използват невронни мрежи, за да валидират своите твърдения. Не е налице консенсус относно валидността на „Хипотезата за ефективния пазар”, но много анализатори на пазара са склонни да вярват, че слабостите и са повече от силните и страни и съвсем естествено отказват да споделят техните печеливши инвестиционни стратегии, които да послужат за доказателство срещу нейната валидност. Така, по естествен начин идва и една от основните цели на настоящия дисертационен труд, а именно да се провери дали „Хипотезата за ефективния пазар” е валидна в условията на слабо развит, нисколиквиден пазар на финансови инструменти, какъвто е този на БФБ - София. И още нещо, това ще бъде осъществено с помощта на невронни мрежи, чрез които не е правен подобен експеримент на местния пазар и малкото подобни опити са били насочени в опит за прогнозиране на бъдещи стойности на отделни акции.

Невронни мрежи се използват за предвиждане цените на пазарите на акции, тъй като те са в състояние да научат нелинейни взаимовръзки между входа на системата и нейния изход. Противно на тезата от „Хипотезата за ефективния пазар“, няколко изследователи твърдят, че фондовия пазар и другите видове финансови пазари представляват хаотични системи. Хаосът е нелинеен детерминистичен процес, който има характеристики на случаен, защото не може да бъде лесно изразен. Използвайки способността на невронните мрежи да изучават хаотични, нелинейни системи може да е възможно да се постигнат по-добри резултати отколкото при традиционния анализ и други компютърно-базирани методи за прогнозиране. Тъй като приложението на невронни мрежи във финансовата сфера е толкова многостранно, този труд ще се съсредоточи върху използването на изкуствени невронни мрежи за прогнозиране на фондовия пазар и по-специално този в България.

Като най-достъпен и дори популярен сред хората, фондовия пазар и особено развития, ликвиден такъв е обект на всевъзможни експерименти за прогнозиране. Трудно

е да се назове метод за прогнозиране, с когото да не е експериментирано в опит да се отгатне посоката и магнитута на движение на световно известните индекси, служещи за бенчмарк за представянето на пазарите на акции като: Dow Jones Industrial Average, Euro Stoxx 50, Nikkei 225, DAX 30, глобалните индекси от групата MSCI и други, докато за по-неликвидни и непопулярни индекси, каквито безспорно са българските – такива експерименти са рядкост и по-скоро обект на академични изследвания отколкото дело на финансовата индустрия. Това е нишата, в която този труд се е прицелил и ще се стреми да обогати малкото, по скромното мнение на автора, изследвания в областта.

Основната цел на настоящия дисертационен труд, дефинирана и в заглавието му е изследване на модели за прогнозиране на капиталов пазар с невронни мрежи. Формулиранни са следните шест задачи, решаването на които ще доведе до постигане на целта:

- Изследване формирането, развитието и способността на невронните мрежи за прогнозиране на капиталовия пазар.
- Анализ на методите за прогнозиране на капиталовите пазари с невронни мрежи.
- Изследване на българския фондов пазар, като обект на прогнозиране.
- Формиране на хибриден модел за прогнозиране на капиталов пазар.
- Провеждане на експерименти с хибридният модел в реалните условия на българския капиталов пазар.
- Обобщаване на постигнатите резултати и бъдещо развитие на модела.

ГЛАВА I: МОДЕЛИ ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИТЕ ПАЗАРИ

1. Прогнозиране на капиталовите пазари

Съществуват множество причини да се желае предсказване на бъдещото движение на цените на активите, търгувани на капиталовите пазари. Първата и най-важна е реализирането на печалба! Тъй като това начинание е непостижимо за огромната част от експериментите в областта, втората най-разпространена причина за провеждането на изследвания в областта е свързана с небезизвестната „Хипотеза за ефективния пазар”. Разработена от Професор Юджийн Фама [6] в края на 60-те години на 20-ти век, тя намира множество поддръжници и критици. Според него акциите се търгуват винаги по справедливата си стойност, което прави невъзможно инвеститорите да купуват подценени акции или да продават акции за завишени цени. Съществуват три варианта на хипотезата: "слаба", "полусилна" и "силна" форма.

Слабата форма на „Хипотезата за ефективния пазар” твърди, че информацията за търговия (нива и промени в цените и обемите) на търгуваните активи (например акции, облигации или имоти) вече е отразена в техните цени. Ако е налице слабата форма на „Хипотезата”, тогава техническият анализ не би могъл да се използва за получаване на предимство и по-висока възвръщаемост. При нея, бъдещите цени не могат да се предвидят чрез анализ на цените от миналото. Доходност, превъзхождаща пазарната, не може да бъде спечелена в дългосрочен план, като се използват инвестиционни стратегии, базирани на исторически цени на акции или други исторически данни. Техниките за технически анализ няма да могат постоянно да генерират превъзхождаща доходност, въпреки че някои форми на фундаментален анализ все пак биха могли да осигурят възвръщаемост над пазарната. Цените на акциите не показват повтарящи се зависимости, което означава, че няма шаблон за движението на цените на активите. Това означава, че бъдещото движение на цените се определя изцяло от информация, която не се съдържа в ценовата база данни. Следователно цените трябва да следват произволна блуждаене. Тази „мека“ форма на „Хипотезата за ефективния пазар” не изисква цените да останат в равновесие или близо до него, а само че участниците на пазара не могат да извлекат системна печалба от неефективността на пазара [7]. Освен това, твърди че съществува положителна корелация между степента на тренда и продължителността на изучавания период от време (но трябва да се има предвид, че през дълги периоди от време трендовете представляват една синусоидална) [8].

В академичните финанси има обширна литература, която се занимава с ефекта на инерцията, идентифициран от Джегадеш и Титман [9] [10]. Акции, които са се представили сравнително добре (или лошо) през последните 3 до 12 месеца, продължават да се представят добре (или лошо) през следващите 3 до 12 месеца. Стратегията за възползване от инерцията се използва успешно на финансовите пазари отдавна, като за прилагането и се откриват къси позиции (продават се акции, без те да се притежават реално от продавача) на акциите на губещи компании и се купуват такива на печеливши компании, като тази стратегия е в състояние да създава положителна средна възвръщаемост, коригирана спрямо риска. Въпреки че се основава на доходността на акции за минали периоди, ефект на инерцията се приема от Фама, като основна аномалия [11].

Полусилната форма на Хипотезата твърди, че цените включват цялата публично достъпна информация (която включва и информация, налична във финансовите отчети, други документи достъпни до регулаторните органи и професионална и

непрофесионална “публика” и т.н.). Ако е налице полусилната форма, нито техническият, нито фундаменталният анализ не би следвало да могат да бъдат използвани за генериране на по-добра възвръщаемост. За да се тества ефективността на полусилна форма, корекциите на неизвестни досега новини трябва да са с разумен размер и трябва да бъдат моментални. За да се провери това, трябва да се търсят постоянни корекции нагоре или надолу след първоначалната промяна. Ако има наличие на такива корекции, това би предположило, че инвеститорите са тълкували информацията пристрастно и следователно по неефективен начин.

Силната форма на „Хипотезата за ефективния пазар” твърди, че цените включват цялата публична и непублична (включително и вътрешна) информация, поради което дори разполагащите с вътрешна информация (т.нар. инсайдъри) не могат да очакват да получат възвръщаемост, превъзхождаща тази на широкия пазар (включително неинформираната общественост), когато търгуват с активи, за които имат вътрешна информация. Не съществува количествена мярка за ефективност на пазара и да се тества идеята е трудно. Така наречените „изследвания на ефекта“ дават едни от най-добрите доказателства, но те са отворени за други тълкувания.

Хипотезата за ефективните пазари посочва, че нито една система не може непрекъснато да се представя по-добре от общия пазар на акции, защото ако тази система стане публична, всеки ще започне да я използва, като по този начин се елиминира потенциала и за печалба. По темата постоянно се дебатира, а валидността и се поставя на множество тестове. Някои изследователи се опитват да използват невронни мрежи, за да валидират своите твърдения. Не е налице консенсус относно валидността на „Хипотезата за ефективния пазар”, но много анализатори на пазара са склонни да вярват, че слабостите и са повече от силните и страни и съвсем естествено отказват да споделят техните печеливши инвестиционни стратегии, които да послужат за доказателство срещу нейната валидност.

Множество инвеститори и изследователи в областта оспорват Хипотезата за ефективен пазар, както емпирично, така и теоретично. Икономистите, принадлежащи към общността на Поведенческите финанси приписват несъвършенствата на финансовите пазари на комбинация от когнитивни пристрастия като свръх увереност, свръхреакция, представителни пристрастия, информационни пристрастия и различни други предсказуеми човешки грешки в разсъжденията и обработката на информация. Тези грешки в разсъжденията подтикваат повечето инвеститори да избягват стойностни акции (value stocks) и да купуват акции на растежа (growth stocks) на високи цени, което позволява на онези, които разсъждават правилно да печелят от изгодни покупки на подценени ценни книжа и продажба на надценени акции на растежа.

Така, по естествен начин идва и една от основните задачи на настоящия дисертационен труд, а именно да се провери дали наистина „Хипотезата за ефективния пазар” е валидна в условията на слабо развит, нисколиквиден пазар на финансови инструменти, какъвто е този на БФБ - София. И още нещо, това ще бъде осъществено с помощта на техника от изкуствения интелект, чрез която на автора не е известно да е правен подобен експеримент на местния пазар - изкуствените невронни мрежи.

Невронни мрежи се използват за предвиждане цените на пазарите на акции, тъй като те са в състояние да научат нелинейни взаимовръзки между входа на системата и нейния изход. Противно на тезата от „Хипотезата за ефективния пазар“, няколко изследователи твърдят, че фондовия пазар и другите видове финансови пазари представляват хаотични системи. Хаосът е нелинеен детерминистичен процес, който има характеристики на случаен, защото не може да бъде лесно изразен. Използвайки способността на невронните мрежи да изучават хаотични, нелинейни системи може да е

възможно да се постигнат по-добри резултати отколкото при традиционния анализ и други компютърно-базирани методи за прогнозиране.

Освен за прогнозиране на финансовите пазари, невронни мрежи са обучавани и за да разрешават различни финансови и икономически задачи. Съществуват експериментални и търговски системи, които се използват за проследяване и прогнозиране на: пазара на фючърси върху суровини, валутна търговия, финансово планиране, и предсказване на фирмен банкрут. Съществува информация, че някои банки използват невронни мрежи, за да оценяват искания за заеми и за изчисляване на вероятността за несъстоятелност на фирми и физически лица. Инвестиционните мениджъри могат да използват невронни мрежи, за планиране и изграждане на печеливши портфейли в реално време. Тъй като приложението на невронни мрежи във финансовата сфера е толкова многостранно, този труд ще се съсредоточи върху използването на изкуствени невронни мрежи за прогнозиране на пазара на акции (фондовия пазар) и по-специално този в България.

Като най-достъпен и дори популярен сред хората, фондовия пазар и особено развития, ликвиден такъв е обект на всевъзможни експерименти за прогнозиране. Трудно е да се назове метод за прогнозиране, с когото да не е експериментирано в опит да се отгатне посоката и магнитута на движение на световно известните индекси, служещи за бенчмарк за представянето на пазарите на акции като: Dow Jones Industrial Average, Euro Stoxx 50, Nikkei 225, DAX 30, глобалните индекси от групата MSCI и други, докато за по-неликвидни и непопулярни индекси, каквито безспорно са българските – такива експерименти са рядкост и по-скоро обект на академични изследвания отколкото дело на финансовата индустрия. Това е нишата, в която този труд се е прицелил и ще се стреми да обогати малкото, по скромното мнение на автора, изследвания в областта.

1.1 Традиционните аналитични методи, използвани за прогнозиране на капиталовите пазари

Преди ерата на компютрите, хората са търгували акциите и суровините основно базирайки се на интуицията си. Докато размера на инвестициите и търговията непрестанно нараства, хората започват да търсят инструменти и начини, които да увеличат техните печалби, като същевременно свеждат до минимум поетия риск. Статистически методи, технически анализ, фундаментален анализ, линейна регресия и други, са използвани в опит да се предскаже посоката на движение на пазара, за да могат създателя им да се облагодетелства от това. Нито една от тези техники не се е доказала, като инструмент за постоянно и точно прогнозиране, дори някои анализатори поставят под съмнение ползата от тези методи. Въпреки това, тези методи ще бъдат накратко представени, тъй като те са често използвани в практиката и представляват конвенционалните методи или с други думи - стандарта, с който изкуствените невронните мрежи, като средство за прогнозиране трябва да бъдат сравнявани. Също така, много от тези техники са използвани за предварителна обработка на входящи данни, както техните резултати се подават на невронните мрежи като входяща база от данни.

1.1.1 Фундаментален анализ

Фундаменталният анализ включва задълбочен анализ на финансовите резултати на дадена компания, за да се определи цената на акциите ѝ. С изучаването на общите икономически условия, конкуренцията на компанията, и други фактори, не е възможно

да се определи очакваната възвръщаемост и вътрешно присъщата стойност на акция. Този тип анализ предполага, че настоящата (и бъдеща) цена зависи от тяхната вътрешна стойност и очакваната рентабилност на инвестицията. Когато нова финансова информация отнасяща се за операциите на компанията бъде публикувана, очакваната възвръщаемост на акция на дружеството се променя, което се отразява на нейната цена.

Сред предимството на фундаменталният анализ е неговия системен подход и способността му да предскаже промени в показателите на компанията преди да са се отразили в графиката на нейната цена. Компаниите се сравняват една с друга, и техните перспективи за растеж се разглеждат в контекста на настоящата икономическа обстановка, което помага на инвеститора да е по-добре запознат със състоянието на компанията. От гледна точка на всеобхватност, фундаменталния анализ е може би най-добрият в това отношение, като включва множество качествени и количествени проверки на една компания, включително нейният бизнес модел, конкурентни предимства, мениджмънт, корпоративно управление, детайлно разглеждане на баланса, отчета за приходите и разходите, отчета за всеобхватния доход, отчет на паричните потоци и много други. За съжаление, е изключително трудно и времеемко да се формализира цялата тази информация за целите на автоматизацията (с изкуствена невронна мрежа например), и интерпретация на тези данни може да бъде субективна. Също така е трудно да се уцели точния момент за осъществяване на сделки базирани на фундаментален анализ, защото дори достигнатите заключения за движението на цената на даден финансов инструмент да са верни, същинското поведение на цената може да бъде отложено във времето поради множество фактори, сред които може да е скоростта с която останалите участници на пазара достигнат или не до идентични заключения. Въпреки това, фундаменталния анализ е метод превъзхождащ останалите когато се отнася за дългосрочната стабилност и растеж. Фундаменталния анализ предполага инвеститорите да подхождат логично и прагматично в разглеждането на инвестициите си в детайли, докато например техническият анализ, предполага инвеститорите да реагират и на психологически фактори, които променят пазарната среда.

1.1.2 Технически анализ

Идеята зад техническият анализ е, че цените на инструментите, търгувани на финансовите пазари и акциите в частност се движат в трендове. Тези трендове са задвижвани от постоянно променящото се настроение на инвеститорите, в следствие и като реакция на различни фактори свързани с пазара. С помощта на ценова статистика, данните за изтъргуван обем, както и отворените позиции към определен момент от времето, финансовите анализатори използват графики, за да предвидят бъдещото движение на цените на финансовите инструменти. Техническият анализ почива на допускането, че историята непрекъснато се повтаря и че бъдещото развитие на цените може да бъде предречено на база на изследването на цените от миналото. Поради тази причина техническият анализ се смята за дискуссионен, дори спорен и противоречащ на теорията за ефективния пазар. Въпреки това той е инструмент използван от преобладаващата част професионалисти и любители - участници на пазарите на акции, валути, облигации, фючърси и стоки и др. Независимо от широкото си разпространение, техническият анализ е критикуван и за високото си ниво на субективност, с него различните индивиди могат да тълкуват едни и същи графики по различен начин.

Ценовите графики се използват за откриване на тенденции. Приема се, че трендовете се основават на въпроси свързани с предлагането и търсенето, които често са циклични. Съществува голямо разнообразие на технически индикатори получени от анализа на графиките, които може да се формализират като правила за вземане на

решения за покупка и продажба, както и да бъдат използвани като входящи данни за изкуствени невронни мрежи. Някои технически индикатори включват филтриращи показатели, показатели за инерцията на цената (momentum показатели), анализи на тренд линии, теория на циклите, индикатори за обема, анализи на вълните и анализи на начини на поведение. Подобни индикатори могат да осигурят информация за краткосрочна и дългосрочната посока на движение, да подпомогнат разпознаването на трендове или цикли на пазара, или да определят силата на движението на цената на финансов инструмент, чрез използването на нива на съпротива и подкрепа.

Един пример за индикатор използван от техническия анализ е пълзящата средна (moving average). Тя осреднява цената за определен период от време (в зависимост от предпочитанията на анализатора), позволявайки по този начин трендове да се виждат по отчетливо. С помощта на пълзящата средна са разработени различни правила за търговия, като например „когато цената на затваряне премине над нивото на пълзящата средна това генерира сигнал за покупка“. За жалост тези индикатори много често генерират „грешни“ сигнали и изостават в сравнение с пазара. В случая с пълзящата средна, тъй като тя се изчислява на база на исторически минали цени търгуващите, които я използват често пропускат голяма част от потенциала за печалба преди сигнала за покупка или продажба да бъде генериран. В крайна сметка, въпреки че техническия анализ може да разкрие възможности за печалба на капиталовите пазари, неговият силно субективен характер и забавяне във времето не могат да му позволят да бъде идеален за динамичните пазарни условия в днешно време.

1.1.3 Прогнозиране чрез динамични редове от данни

При прогнозиране на базата на динамични редове се анализират данни от миналото, за да се извеждат проекции и оценки за бъдещите стойности на данните. По принцип, този метод се опитва да моделира нелинейна функция, чрез повтаряща се релация (отнасяне), получена от минали стойности. Повтарящата се релация може да се използва за предвиждане на нови стойности във времевия ред, които да бъдат добри приближения на действителните стойности. В методологическия аспект общото развитие в динамичния ред се разглежда като съвкупност от няколко понятия:

- Тренд това е понятие което включва всички причини които определят основно направление в развитието на масовите явления;
- Случайните колебания, те се проявяват като например зигзагообразно отклонение от общата тенденция на развитие;
- Сезонните колебания са периодично повтарящи се колебания в рамките на годишните периоди с относително постоянна амплитуда;
- Цикличните колебания са периодично повтарящи се в рамките на определен, сравнително по-продължителен интервал от време.

Всички тези понятия са лесно различими и ясно установени на пазара на акции.

Съществуват два основни типа за прогнозиране чрез динамични редове: едновариантен и многовариантен. Едновариантен модел, като моделът на Бокс-Дженкинс [12], съдържа само една променлива в повтарящото се уравнение. Моделът Бокс-Дженкинс е сложен процес на приспособяване на данни към подходящите параметри на модела. Уравненията, използвани в модела съдържат минали стойности от пълзящите средни и цените на финансови инструменти. Бокс-Дженкинс е добро решение за краткосрочно прогнозиране, но изисква твърде много данни, а определянето на съответното уравнение и параметри на модела е сложен процес. Многовариантните

модели целят да откриват случайни фактори, които влияят на поведението на данните. Както името им подсказва, тези модели съдържат повече от една променлива в уравнението си. Регресионният анализ е многовариантен модел, който често бива сравняван с изкуствените невронни мрежи. Като цяло прогнозирането на базата на динамични редове от данни предлага приемлива точност когато се използва за относително кратки периоди от време, но колкото по дълъг е прогнозирания период, толкова и неговата акуратност намалява.

1.1.4 Хипотезата за ефективния пазар

Хипотезата за ефективния пазар гласи, че във всеки един момент цената на даден финансов инструмент е отражение на цялата известна информация за този инструмент. След като всичката налична информация се използва оптимално от участниците на пазара, ценовите вариации са случайни, тъй като новата информация се появява на случаен принцип. Вследствие, цените на финансовите активи осъществяват „случайно блуждаене” и не е възможно един инвеститор да се „пребори” с широкия пазар, като постигне по-висока доходност.

Въпреки че това твърдение звучи неправдоподобно и неизчерпателно, не съществуват много доказани теории, които да го оборят. Разработени са множество изследвания, включително и такива, използващи невронни мрежи в опит да подложат под съмнение или да потвърдят хипотезата, и въпреки това, тъй като невронните мрежи са толкова добри, колкото добре са били обучени е трудно да се спори за приемането или отхвърлянето на хипотезата, само на основание представянето на една или няколко невронни мрежи. На практика, сригове на фондовия пазар, като пазарния сриг през Октомври 1987 г., противоречат на хипотезата, защото те не се основават на информация получена на случаен принцип, а възникват в следствие на натрупване на твърде много страх в инвеститорите.

“Хипотезата за ефективните пазари” е важна, защото противоречи на всички останали форми на анализ и прогнозиране, поради факта че ако тя е вярна и е невъзможно да се „победи” пазара (реализира по-добра доходност от пазарната) тогава фундаментален, технически и другите методи за прогнозиране не би следвало да водят до по-добър резултат от едно случайно предположение. Фактът, че множество пазарни участници съумяват да реализират по-висока доходност от пазарната за продължителни периоди от време показва, че хипотезата на практика не е вярна, но същевременно поддръжниците ѝ отдават това на случайността. По скромното мнение на автора, тя би могла да е вярна само в условията на перфектна конкуренция на капиталовите пазари и равномерно и еднакво разпространение на информацията, но в днешно време това далеч не е така и не може да се твърди, че един обикновен инвеститор разполага със еднакъв достъп до пазара на акции с големите инвестиционни фондове и банки. Съществуват някои привилегирани участници на пазара които имат преимущество в благодарение на неограничените си ресурси, бърз достъп до търговия, вътрешна информация и множество други фактори, които им гарантират конкурентно преимущество пред „редовите“ участници на капиталовите пазари. Много добър пример за това е иновативното поле на Високочестотната търговия, където от съществено значение е дори физическата локация на участниците на пазара [13].

1.1.5 Теория на Хаоса

Теорията на хаоса [14] анализира даден процес в рамките на предположението, че част от този процес е детерминистична, а част от процеса е случайна. Хаосът е нелинеен процес, който изглежда като случаен. Различни теоретични тестове са разработени, за да се провери дали дадена система е хаотична (дали е налице хаос във времевите редове). Теорията на хаоса е опит да се покаже, че съществува определен ред в очевидната случайност. Като се допусне, че капиталовият пазар е хаотичен, а не просто случаен, теорията на хаоса противоречи на Хипотезата за ефективния пазар.

По същество, една хаотична система е комбинация от детерминистичен и случаен процес. Детерминистичния процес може да се характеризира с наместване на регресия, докато случаен процес може да се характеризира от статистическите параметри на функция на разпределението. По този начин, като се използват само детерминистични или статистически методи не може напълно да се улови характера на хаотична система. Способността на невронните мрежи да улавят детерминирани и случайни функции ги прави идеални за моделиране на хаотични системи.

1.1.6 Други техники

Много различни техники, базирани на компютърен софтуер са разработени за да се прогнозира бъдещото движение на капиталовите пазари, те варират от чартистки програми (използващи ценови графики в комбинация с наложени графични анализи) , до софистицирани експертни системи и софтуер базиран на размити множества.

Експертните системи обработват знания последователно, като ги формулират като правила, те могат да бъдат използвани за да съставят правила за търговия, базирани на технически индикатори. В това си качество експертните системи могат да бъдат използвани заедно с невронни мрежи за прогнозиране на пазара. В подобна хибридна система невронната мрежа може да осъществява прогностичен анализ, а експертната система да извършва валидация на прогнозата, на базата на предефинирани, общоприети правила.

Предимството на експертните системи е, че те могат да дадат обяснение за своите прогнози, докато при невронните мрежи е по-трудно да се анализира важността на входящите данни и това как мрежата достига до своите резултати, но за сметка на това са по-бързи, защото те осъществяват паралелно изчисляване и са толерантни към грешки.

Основният проблем с прилагането на експертни системи на капиталовия пазар е трудността при формулирането на познания за пазарите, тъй като самите ние не ги разбираме напълно [5]. Невронните мрежи имат предимство пред експертните системи, тъй като те могат да извлекат правила, без да се налага да ги формализират точно. В много хаотична и само частично разбирана среда, като тази на капиталовия пазар, това е важен фактор. Трудно е да се извлече информация от специалисти в областта и да се формализира по начин, удобен за използване от експертни системи. Експертните системи имат добра успеваемост само в рамките на тяхната сфера на знания и не работят добре, когато има липсваща или непълна информация. Невронните мрежи се справят с динамични данни по-добре и могат да обобщават и да правят предположения. По тази причина невронните мрежи са по-подходящи за средата на капиталовия пазар, отколкото експертните системи.

1.1.7 Кратко обобщение за традиционните методи за прогнозиране

От голямото разнообразие от различни техники и модели, представени досега, всяка има своите привърженици и противници, както и своите предимства и недостатъци. Общата цел на всички методи е прогнозирането на посоката и магнитуда на бъдещите пазарни движения на базата на информация от миналото. Предложенията, направени от всеки метод диктуват неговото представяне и колко широко приложение ще намери в стратегиите на участниците на пазара.

Хипотезата за ефективния пазар възприема, че информацията се разпространява паралелното и че пазара е непредвидим и случаен. Поради тази му характеристика, няма техника за прогнозиране, която да може постоянно да „побеждава“ пазара, тъй като всички участници биха започнали да я прилагат, което на свой ред ще доведе до изчезване на възможността от реализиране на печалби, над пазарните. Не би било спекулативно ако се каже, че хипотезата за ефективния пазар има своите предимства, чисто теоретично, но в реалния свят все по-очевидно се забелязва неравнопоставеността между различните участници на капиталовите пазари. Някои участници на пазара имат много повече повече информация и инструменти за своевременно намиране на информация от други, което им позволяват да реализират по-добра доходност от пазарната, други чрез помощта на манипулации успяват да се възползват от несъвършенствата на пазарната инфраструктура. Така цените на търгуваните на капиталовия пазар инструменти не са просто случайни – те се получават, като следствие от действието на сложна динамична система, влияние върху която оказват безброй много фактори, твърде много, за да бъдат напълно отчетени от всеки участващ в системата.

Техническият анализ възприема тезата, че историята непрекъснато се повтаря и определени тенденции могат да бъдат разпознавани, чрез използването на графики. Фундаменталният анализ влиза в помощ на дългосрочните инвеститори, помагайки им да изчислява вътрешната стойност на финансов инструмент и посоката на движението на цената за бъдещи периоди, като възприема, че участниците на пазара взимат рационално решенията за покупка и продажба. Чрез статистическия и регресионния анализ се прави опит да се формулират повтарящи се уравнения и модели, които да предричат бъдещото движение на цените на база на минало такова. Накрая, теорията на хаоса твърди, че привидната случайност на пазара е прекалено сложна за разбиране нелинераност. Всеки един от тези модели за прогнозиране, използвани в областта на капиталовите пазари има своите преимущества и недостатъци. Поради тази причина няма един единствен, който да е всепризнат за превъзхождащ останалите.

Капиталовият пазар може да се опише, като хаотичен, той може да бъде предвидим в определен период от време, а в други случаи движенията му да се окажат напълно случайни. Причината за това е, че човешкото поведение не е нито напълно предвидимо, нито напълно случайно. Въпреки че е почти невъзможно да се определи реакцията на човек в различни ситуации, винаги съществуват някои основни тенденции в поведението, както и някои случайни елементи. Капиталовият пазар е средище на милиони хора, действащи по един хаотичен начин. Невъзможно е да се предскаже поведението на един милион души, така като е невъзможно да се предскаже поведението дори на един единствен човек в определени ситуации (особено на риск, напрежение и стрес). Инвеститорите не се влияят предимно нито от психологически фактори, както е предвидено от техническия анализ, нито от фундаментални фактори, както е предсказано от фундаментален анализ. Човешкият подход и поглед върху света варира дневно по начин, който дори самите индивиди не разбират напълно, така че такова поведение следва да се пренася и на капиталовия пазар.

В заключение може да се посочи, че тези методи работят най-добре когато се използват в комбинация един с друг. Основната полза от използването на невронна мрежа е тя да бъде обучена как да използва в комбинация тези методи ефективно и по този начин изкуствената невронна мрежа евентуално да бъде научена как пазарът се държи като фактор на нашето колективно съзнание.

1.2 Прогнозиране на капиталовите пазари – общи положения

Сред основните задачи на този труд е да се осъществи успешно прогнозиране на бъдещото развитие на капиталовия пазар в България. Идеята на автора е да се използва хибриден модел, основан на техники от Изкуствения интелект, в това число невронни мрежи и системи основани на правила. Невронните мрежи представляват компютърни програми, проектирани да се обучават по начин, подобен на човешкия мозък. Невронните мрежи са продължение на модела на перцептрон с добавен един или повече скрит слой, с нелинейни трансферни функции в скритите неврони. Тяхната структура включва поне един скрит слой и това им позволява да бъдат считани от мнозина за универсален апроксиматор, който е в състояние да научи всяка непрекъсната функция, определена в област (входовете ѝ имат определени граници, вместо да нямат граници на това, което могат да представляват), както и функции, които се състоят от краен сбор от точки. Но преди да се задълбочи повече в разглеждането на формирането, развитието и техниките на Изкуствения интелект, както и невронните мрежи като негово направление, е редно да бъдат разгледани някои общи положения при прогнозирането на капиталови пазари при считаните за традиционни методи за прогнозиране, част от които вече бяха споменати тук.

Същността на всеки един модел е в това да успее да предскаже стойността на даден параметър в един последващ етап. И тук нещата започват да се сегментират в зависимост най-вече от обекта и целите на изследване, както разбира се и времевия хоризонт.

Финансовите инструменти, чийто цени са обект на прогнозиране могат да бъдат всякакви търгуеми активи, като валути, акции, права, депозитарни разписки, варанти, договорни фондове, борсово търгуеми фондове, договори за разлика, депозити, държавни, общински и корпоративни облигации, опции, фючърси, форуърдни договори и всички стандартизирани договори, структурирани продукти и пр. Важно условие е да има възможност за търгуването им, като това позволява на практика да бъде реализирана и положителна разлика между цената на закупуване и тази на продажба. Колкото повече участници на конкретния пазар, толкова по-голяма е неговата „дълбочина“, което обуславя един изключително важен елемент – ликвидността. Тя може да се измерва по множество показатели, най-важните от които са: изтъргуван обем измерен в пари, изтъргувани инструменти (брой, номинал и т.н.), брой сделки, времетраене на търговията и пр. По традиция участниците на капиталовите пазари са привлечени повече от по-ликвидните средища и инструменти, за сметка на по-неликвидните такива, за разлика от тази тенденция, авторът на дисертацията е насочил своето внимание към един доста неликвиден и недоразвит пазар, като БФБ – София. Основните разлики и произтичащите от тях особености ще бъдат разгледани на по-късен етап.

Сред задачите могат да бъдат открити две: научно доказване или оборване на дадена теория или хипотеза, както е в този случай и разбира се преобладаващата – да бъде извлечена печалба от направена инвестиция или спекулация. Разликата между инвеститори и спекуланти обикновено се дефинира чрез времевия хоризонт на намеренията им, като инвеститорите се асоциират с по-дългосрочни намерения, а спекулантите с по-краткосрочни. Независимо от това както какви се определят и вечните

спорове за ползата от наличието на участници на пазара, които гледат на него като на хазартна игра, всички допринасят за това да има по-активна търговия и да продължава развитието на средищата за търговия. Относно средищата за търговия, те биват най-генерално определени като два вида – борсова и извънборсова.

Борсите, както най-често се наричат, са официални пазари на финансови инструменти, на които се действа по строго определени правила, с определени стандарти и определени инструменти. Друг употребяван термин е многостранна система за търговия – организирана от пазарен оператор, чрез която се осъществява покупко-продажба на финансови инструменти по правила и начин, организиран от пазарния оператор и в съответствие със законодателството [15]. Борсите могат да бъдат фондови, на които се търгуват предимно акции, права и фондове, от където идва определянето им като фондови борси (макар превода на български език да не е много интуитивен) и стокови, на които се търгуват предимно стандартизирани деривативни контракти на стоки, валути и др. Най-известни представители на двата вида са Нюйоркската фондова борса (New York Stock Exchange) и Чикагската стокова борса (Chicago Mercantile Exchange). Българските еквиваленти на тези два мастодонта в финансовия свят са БФБ – София и Софийска стокова борса. Доскоро, тези официални пазари и подобните им бяха единствените места за търговия, но това бе променено с Директивата за пазарите на финансови инструменти, известна като MiFID [16] децентрализира този бранш и позволи организирането на т.нар. многостранни системи за търговия, което значително промени нещата на пазара, като подобри ликвидността, но усложни достъпа до подобни средища и обуславя навлизането на алгоритмичната търговия. В България е налична само една подобна многостранна система за търговия на акции, организирана от инвестиционния посредник и Капман АД наречена MTF Sofia.

Извънборсовата търговия е свързвана най-често с търговията на валута и на държавни, общински и корпоративни облигации. Тя е децентрализирана форма на търговия, при нея не съществуват правила, макар участниците да се водят от тези, действащи на борсовите пазари. Трудно е да се добие информация за цени и изтъргувани обеми, могат да се правят само допускания и това го прави по-сложен обект за научни и пазарни изследвания.

Времевия хоризонт е друга съществена част, която трябва да се отчита при изследването на пазарите. Сред академичните среди преобладава разбирането да се използват данни за продължителни периоди от време, най-вече на дневна база. Някои изследователи правят своите експерименти на база 10 – годишен период, който може да бъде прекалено дълъг не само за индивидуалните инвеститори, но дори и за професионални такива. От друга страна спекулантите много често са ангажирани в т.нар. дневна търговия, която включва активна покупко-продажба през работните часове на съответните капиталовите пазари, като на края на деня всички отворени позиции (покупки или продажби) се закриват. Тук използваните входящи параметри за моделите за прогнозиране вече са на часова, минутна и дори милисекундна база. Когато говорим за търговия с акции те стратегиите могат да бъдат дефинирани най-общо по следния начин:

Инвестиции в растеж: Стратегическите методи, които се фокусират върху инвестициите в растеж, имат за цел да идентифицират акции, които показват най-добри перспективи за растеж. Най-общо казано, това означава да се идентифицират компаниите, които са в зряла фаза на своя бизнес цикъл. Например, акциите на технологичните компании са привлекателни за много инвеститори търсещи растеж, тъй като тези те обикновено стават публични, за да привлечат капитал, за да станат още по-големи.

Инвестиции в стойност: Стратегическите методи, които се фокусират върху инвестирането на стойност, са насочени към идентифициране на акции, които показват най-добра „стойност“ за парите инвестирани в тях. Акциите на растежа всъщност често са прекалено скъпи, тъй като предлагат най-добрите перспективи за бъдещето. Акциите, които предлагат стойност обикновено са с понижена цена поради скорошни негативни новини или лошо управление. Инвеститорите в стойност ще търсят промени в обстоятелствата и ще инвестират в обрат в историята на компанията.

Инвестиции в доходност: Подходите, които се фокусират върху инвестиции в доходност, са насочени към акции на компании, които предлагат сериозна фиксирана доходност (изплащат дивиденди). Въпреки че тези акции може да са доста привлекателни за инвеститори, които не желаят да рискуват прекалено много, стойността им може да се понижи, когато например лихвените нива се покачат. По този начин инвестицията може да се окаже губеща, въпреки изплащането на дивиденди.

Резултатите от изградените модели за прогнозиране на цените на финансовите инструменти търгувани на и извън борсите могат да бъдат разделени според целите на провеждането им. Прегледателите на научните среди отчитат предимно успехи в техните трудове под формата на ниски стойности на грешката при прогнозиране, в голямата си част те са обнадеждени от резултатите които продуцират. Не така двояко стоят нещата при стратегиите за търговия които инвестиционните фондове. Там резултатите се променят в рамките на седмици и дори дни, като цяло съществува цикличност на доброто представяне на различни играчи по различно време, без това да бъде отдадено на промени в тяхната стратегия, а по-скоро на нейното постоянство.

1.3 Изкуствен интелект

Може би най-разпространената дефиниция за изкуствен интелект е така нареченият тест на Тюринг. Алън Тюринг [17] е английски математик известен както с „Машините на Тюринг“, така и с разбиването на немските кодове по време на втората световна война, заслужила му честта, образът му да стои на новата банкнота от 50 британски паунда. Тюринговият тест е доста прост а съвременната му интерпретация изглежда по следния начин: Човек взаимодейства дистанционно с двама събеседници – компютър и човек; на основание на отговорите на въпросите, тестовият субект е длъжен да определи с кого разговаря – с машина (изкуствен интелект/компютърна програма) или с жив човек; задачата на компютърната програма е да въведе човека в заблуда, карайки го по този начин да направи грешен избор.

Изкуственият интелект се описва, като софтуер, който по някакъв ограничен начин се държи като човешко същество. Думата изкуствен (artificial) идва от латински, коренът на думата - *facere arte* означава "да се направи нещо", така изкуствен интелект се превежда свободно като „интелект, създаден от човек“. Научни определения за изкуствен интелект са дефинирани по много начини: П. Уинстън [18] го дефинира по следния начин: „Изкуственият интелект е наука за концепциите, които позволяват на компютрите да правят такива неща, които за хората изглеждат разумни“. Рич и Найт [19] определят изкуственият интелект като „проучването за това как да направят компютрите да вършат неща, които в момента хората правят по-добре“.

Други по-често срещани дефиниции и определения за изкуственият интелект са:

- Изкуственият интелект е интелигентен защото се учи;
- Изкуственият интелект преобразува данни в познание;
- Изкуственият интелект е за интелигентен начин на решаване на проблеми;

- Изкуственият интелект възплащава способността да се адаптират към околната среда, за да се справят с непълни или неправилни данни.

Докато техниките на изкуствения интелект присъстват в областта на финансите от относително скоро, те имат дълга история на използване в много други области. Досегашният опит от приложението им в широк спектър от нефинансови области [139] е бил спорен и непостоянен. Патрик Уинстън – водещ изследовател в областта на ИИ и ръководител на лабораторията по ИИ в Масачузетският технологичен институт признава, че традиционните методи на изкуствения интелект, като Предикатното смятане, Експертни системи основани на правила, и т.н. са постигнали малък напредък.

Проблемната област за ИИ, в които те традиционно търпят неуспех са в тривиалните задачи и тези продукт на здравия разум, които хората намират за изключително лесни за разрешаване, като например разпознаване на обекти, ходене и т.н.

Поради тази причина по естествен начин изследователите на Изкуствения интелект са се обърнали към природата и законите на физиката и различни физични процеси, за да потърсят вдъхновение за намирането на по-добри решения. В резултат на това много от съвременния инструментариум е разработен в областта на природните науки и инженерството и успешно са намерили своето търговско приложение. Като такива примери могат да бъдат дадени Уейвлет трансформации [20] (Wavelet Transformations), Генетични алгоритми [21] и изкуствените невронни мрежи от биологичните науки, Теорията на хаоса и Симулирано закаляване от физическите науки. Тези революционни техники попадат в областта на Изкуствения интелект, тъй като те впрягат разум в техния подход към решаване на различни проблеми от търговски характер. Всички тези инструменти имат една обща нишка - те се опитват да решават проблеми като прогнозирането на данни за финансови пазари и тяхното обяснение чрез прилагане на физични закони и процеси. С. Пал и П. Сримини [22] изтъкват, че тези иновативни изчислителни модели, в последствие станали известни като Софт компютинг притежават уникалната способност да използва неточността, толерантността и несигурността в проблемите от реалния свят, за да се постигне добра податливост при обработка, устойчивост и ниска цена. Те също така посочват, че Софт Компютинг често се използва, за намиране на приблизителното решение за точно или неточно формулиран проблем.

Тези съвременни инструменти често се използват в комбинация един с друг, както и с по-традиционните методи на Изкуствения интелект, като Експертни системи, за да се получат по-добри решения. Тези нови системи, съчетаващи един или повече методи, в комбинация с друг от традиционните методи са известни като "хибридни системи". Един пример за хибридна система е системата за финансова търговия описан от К. Тан [5], който съчетава изкуствена невронна мрежа с основана на правила експертна система, (Rule-based expert system). Р. Лорънс [23] предпочита да използва терминът компютърна интелигентността, за да опише експертните системи и изкуствени невронни мрежи, защото го счита за подвеждащо и по-малко спорно при определянето на "интелигентността" породена от такива системи.

Изкуствените невронни мрежи далеч не са единствените използвани за прогнозиране на капиталовия пазар, но със сигурност са сред най-популярните.

Способността на изкуствените невронни мрежи да откриват нелинейни взаимоотношения във данните използвани, като входяща информация, ги прави подходящи за моделиране на нелинейни динамични системи, като капиталовите пазари и по-специално този на акции. Множество различни модели, на основата на изкуствени невронни мрежи са разработени за прогнозиране на пазара на акции. В научните среди тези модели най-често са разработвани с цел да бъде установена валидността на

Хипотезата за ефективните пазари, разработена от Юджийн Фама или за да бъдат съпоставени със статистически модели за прогнозиране. Често, за входящи параметри на подобни модели се използват данни от фундаменталния и техническия анализ и техни производни. Тук ще бъде разгледано използването на изкуствени невронни мрежи на капиталовите пазари с цел прогнозирането им, включително данните използвани, като вход за системите, продуцираните резултати и организацията на самите мрежи.

В днешни дни огромни количества капитал се търгуват чрез фондовите пазари по света. Според данни на Световната банка [2], към 2018 г. световната борсова пазарна капитализация възлиза на около 68.7 трилиона щатски долара. Националните икономики са силно свързани и силно повлияни от представянето на техните пазари на акции. Освен това, пазарите са все по-достъпни за инвестиране, не само за стратегически инвеститори, но и за обикновените хора, както това се дължи главно на техническите иновации и развитието на новите технологии, но също така и на “разхлабването” на регулаторната рамка от страна на властите. Следователно те не се влияят само от макроикономически и макроикономически данни, но и от всекидневния живот по един по-директен начин. Затова те представляват механизъм, който има важни и преки социални въздействия. Една от основните характеристики, която всички фондови пазари притежават е несигурността, свързана с бъдещото им състояние в краткосрочен и дългосрочен план. Тази неизвестност е нежелана от инвеститора, но също така и неизбежна, когато фондовия пазар се разглежда като инвестиционна възможност. Най-доброто, което индивидуалните и институционалните инвеститори могат да направят, е да се опитат да намалят тази несигурност. Процесът за осъществяването на това се нарича прогнозиране, предвиждане или отгатване на бъдещото движение на пазара.

Задачата за прогнозиране на движенията на капиталовите пазари разделя изследователите на две групи. Тези които смятат, че съществуват и могат да бъдат разработени механизъм и модели за отгатването, и тези които вярват, че пазарът е рационален и ефективен и всяка нова го информация, която го засяга се абсорбира моментално, което води до моментални корекции в цените на търгуваните инструменти и не съществува възможност тази нова информация да бъде предвиждана успешно непрекъснато. Освен това, скептиците смятат, че фондовия пазар следва „случайно блуждаене“, което означава, че най-добрата прогноза за стойността на даден финансов инструмент за утрешния ден е днешната му стойност. С други думи вторите принадлежат към привържениците на хипотезата за ефективните пазари, спомената по-рано.


През последните години се наблюдава постоянно разрастване на набора от компютърни технологии, които се използват на финансовите пазари. Сред най-вълнуващите, от гледна точка на способност за прогнозиране са тези, произлизащи от областта на Изкуственият интелект. Един от съвременните методи на изкуствения интелект – изкуствените невронни мрежи, използвани самостоятелно или в комбинация с други техники от полето на изкуствения интелект, започват да добиват все по-голяма популярност, като инструмент за разрешаване на голямо разнообразие на сложни задачи. Търговски приложения, базирани на изкуствените невронни мрежи са внедрени успешно в различни области, вариращи от медицината до изследването на космоса, и масово в изследването на финансовите пазари. В следващите редове ще бъде направен преглед на етапите в развитието на тази техника.

1.3.1 Изкуствена невронна мрежа

Теорията за изкуствените невронни мрежи произхожда от науката за Изкуствения интелект или казано с други думи от теорията за изследване и разработка на машини с когнитивни способности. Изкуствените невронни мрежи представляват компютърни

програми или хардуерни машини, проектирани да се обучават по начин, подобен на човешкия мозък. С. Хайкин ги описва в своята книга, озаглавена Невронни мрежи и обучаващи се машини“[24], като адаптивни машини или по-конкретно: „Невронната мрежа е масивен паралелно дистрибутиращ процесор, който притежава естествена склонност към съхранение на опита и знанията и предоставянето им за ползване. Те приличат на мозъка в два аспекта: знанията са придобити от мрежата, чрез процес на обучение и вътрешно-невронната сила на връзките, известна като тежест на синапсиса, се използват за складиране на това познание.“

Невроните са клетките, намиращи се в човешкия мозък и нервна система. Основният градивен елемент на мозъка и невронната мрежа е невронът. Той е показано на Фигура 1, адаптиран от Бейл и Джаксън [25].



Фигура 1 – Биологичен Неврон

Както Джаксън пише, всички входящи данни в клетъчното тяло пристигат по дендритите, които също така служат и за проводници на изходящата информация, доставяйки я до съседните неврони, по този начин изпълнявайки функция на интерконектор. Математически, функцията на дендритите може да бъде определена, като сумираща. От друга страна аксоните или нервните влакна, който провежда електрически импулси от тялото на неврона се намират само в изходящите клетки, като те притежават потенциал, който ако бъде възбуден до над определен праг предава в електрически сигнал. Аксоните се свързват със синапсите - обозначаващи наличието на специфичен контакт между мембраните на две клетки, от които поне едната е нервна, се свързват с дендритите на други неврони. Когато електрическият сигнал на входа синапсите достигне определен праг, той препредава сигнала към дендритите, към които е свързан. Човешкият мозък съдържа приблизително между 80 и 100 млрд. взаимосвързани неврона, които изграждат неговата масивна, паралелна изчислителна способност.

Изкуствените невронни мрежи са вдъхновени от биологичните науки и по-конкретно от неврологията. Въпреки това приликите с техните биологични прототипи се изчерпват с няколко заети концепции от биологичните системи, предимно свързани с тяхната архитектура. Все пак изкуствените невронни мрежи все още са далече от детайлно наподобяване на работата на техните биологични образци, поради невероятната сложност на биологичните мрежи.

Информацията или казано по друг начин, сигналите между отделните компоненти на невронната мрежа в човешкото тяло се предават едноточено, чрез връзките между невроните, а именно аксоните. Информацията се получава от невроните чрез дендритите. Човешкият мозък е съставен от над сто милиарда неврони и повече от 10^{14} синапси. Невроните „комуникират“ помежду си посредством синапсите, които представляват групи от възли или кръстовища между връзките. Предавателната част на синапсите подава невротрансмитери, които са сдвоени с неврорецепторите на приемащата страна на синапсите. Обучението обикновено се прави чрез адаптиране на съществуващите синапси, въпреки че някои аспекти от обучението и функции за запаметяване се извършват чрез създаване на нови синапси. Невроните в човешкия мозък са организирани в групи и само някаква част от общото им количество участва в разрешаването на дадена задача. На Фигура 1 е изобразена проста невробιοлогична структура, изградена от един неврон и неговите връзки. Аксона на един неврон представлява пътя на изходящата информация, която се разклонява чрез аксонни разклонения, които от своя страна се свързват с дендритите или входните пътеки на съседните неврони посредством възли или кръстовища наричани синапси. Именно чрез тези синапси се извършва по-голямата част от обучението на мрежата чрез възбуждане или чрез инхибиране на тяхната невронна дейност. Въпреки това не всички неврони са адаптивни и могат, образно казано да се нагласят. Синапсите съдържат невротрансмитери, освобождаващи се в съответствие с входящите сигнали. Синапсите възбуждат или инхибират асоциираната невронна активност в зависимост от освободените невротрансмитери. Един биологичен неврон ще добави всички активиращи (възбуждащи) сигнали и ще извади всички потискащи от всички свои синапси, като ще изпрати сигнал до неговия аксон ако разликата между двете е по-висока от неговия праг на активиране. Обработката на информацията в биологичния мозък е високоскоростна и паралелна, както и устойчива на грешки. Характеристиката висока устойчивост на грешки се получава в резултат от претрупаните и повтарящи се невронни пътища и разпространението на информацията в цялата система от синапси в мозъка. Също така, това широко разпространение на информация в мозъка позволява на неровните пътища да се справят с неточни и непълни данни. В миналото е било изключително трудно да се осъществяват експерименти по синтетично възпроизвеждане на процесите, протичащи в човешкия мозък поради лимитираната изчислителна способност на компютрите. Но с навлизането на суперкомпютрите, експерименти стават все по-достъпни, а изчислителните им способности позволяват изграждане на модели, включващи стотици милиони изкуствени неврони, съпоставим брой на тези в човешкия мозък, като например програмата SyNAPSE [25], разработена от IBM, в колаборация с Hewlett-Packard и HRL Laboratories. Тези модели за съжаление продължават да са изключително бавни, като са им нужни часове за да симулират секунда от активността на биологичен мозък.

Изкуствените неврони са разработени с цел да се моделира биологичните неврони в човешкото тяло. Изкуствената невронна мрежа е съставена от множество изкуствени неврони, които се явяват като изчислителни елементи, свързани помежду си чрез претеглени връзки и организирани в слоеве. За да се моделира естествения процес протичащ в човешкото тяло по отношение на електрическата активност на един неврон

така: невронът получава електрически стимули (сигнали) от други неврони, събира всички тези сигнали за да изчисли цялата получена енергия, като част от тази енергия се губи, за да преодолее естественото ниво на съпротивление на неврона и останалата част от енергията се предава на следващите неврони от мрежата.

1.4 Периоди в развитието на изкуствени невронни мрежи

Най-ранните опити да се разбере човешкия мозък датира от преди векове. Като цитират информация. Изучаването на човешкия мозък през голяма част от историята е било ограничено до философския въпрос дали умът и тялото са едно цяло. Както Рич и Найт посочват в началото на книгата им, „Изкуствен интелект“, "Философията винаги е била изучаването на тези клонове на знанието, които са били толкова зле разбрани, че те все още не са станали отделни дисциплини сами по себе си". Това със сигурност е валидно за модерното изследване на мозъка и последващото разработване на изкуствените невронни мрежи. Технология, даваща възможност за изучаването на работата на мозъка не е била на разположение до края на деветнадесети век. Оттам насетне изкуствените невронни мрежи са имали много стръмен и неравен път към славата. Съществуват четири отчетливи периода в развитието им до настоящото им състояние. Р. Еберхарт и Р. Добинс [27] ги класифицират в следния цветущ начин:

- 1890 – 1926 Ерата на Камелот (The Age of Camelot);
- 1969 - 1982 Тъмната ера The Dark Age (Depression Age);
- 1982 – 1986 Съпротивата The Renaissance;
- 1986 – до ден днешен Ерата на Нео конекционизма The Age of Neoconnectionism

Първият период започва в края на деветнадесети век с появата на съвременната наука и стремежа за по-добро разбиране на работата на мозъка. Тъй като технологията по онова време се подобрява, психолози и биолози са в състояние да започнат да градят хипотези за това как функционира човешкия мозък, вместо преобладаващия по онова време въпрос - Защо функционира човешкия мозък? Голяма част от литературата, посветена на Изкуствените невронни мрежи, поставя началото им и това на модерна теория за функционирането на мозъка при публикуването на текст на Уилям Джеймс, озаглавен: "Психология: кратък курс" [28]. Текстът съдържа много прозрения за мозъчната дейност и е предшественик на много от днешните теории.

За да се случи следващия голям пробив в областта, минават цели петдесет години, когато през 1943 Макълх и Питс представят техния първи модел на биологичен неврон [29]. Те разработват теореми, свързани с модели на невронни системи, базирани на знанията за биологичната структура на мозъка към онзи момент. Техните модели са можели да разрешават всички крайни, логически изрази и откакто, като по този начин стават първите автори, които предлагат масивен паралелен невронен модел. Въпреки това моделите им не можело да бъдат обучавани, тъй като използвали само фиксирани тегла на отделните неврони. Доналд Хъб [30], виден психолог, добавил към тези знания с неговата хипотеза за това как невроните комуникират и съхраняват знания в структурата на мозъка. Тази хипотеза става известна като правило за обучение на Хъб допринася за последващото развитие на правилата за обучение на невронни модели на Макълх и Питс.

Този период отбелязва своя пик, когато Франк Розенблат публикува своя забележителен труд, в който дефинира структурата на изкуствена невронна мрежа наречена "Перцептрон: вероятностен модел за съхранение на информация и организация в мозъка"[31]. Той черпел своето вдъхновение от начина, по който функционира човешкото око и изгражда своя модел на перцептрон, базиран на него. В него той

комбиниращ правилото за обучение на Хебиан с модела на неврони на Макълос и Питс. Той използва модела на перцептрон за различни задачи по разпознаване на образи, като да различава геометрични форми и азбуки. Общността на Изкуствения интелект е обнадеедена от първоначалния успех на перцептрона, като очакванията са много завишени и на него се гледало, като на панацея за всички известни по онова време проблеми. Барнет Уидроу и Марсиан Хоф [32] допринасят за този ентузиазъм, когато през 1960 г. публикуват своя труд върху изкуствените невронни мрежи от инженерна гледна точка и представят модел изграден от един неврон наречен ADALINE (Adaptive Linear Neuron или впоследствие известен като Adaptive Linear Element), който в последствие се превръща в първата невронна мрежа използвана за търговски цели. Той намира приложение като адаптивен филтър в телекомуникациите за отстраняване на ехото на телефонните линии. ADALINE ползва алгоритъм на обучение наречен Делта правило (delta rule), което включва използването на метод за намаляване на грешката известен като Градиентно спускане или най-стръмно спускане (gradient descent or steepest descent).

През 1969 г. двама добре познати в тази сфера учени - Марвин Мински и Самюел Пейпърт публикуват своята книга, озаглавена „Перцептрони“ [33], в която те критикуват модела на Франк Розенблат - перцептрон и правят заключението, че този модел, както и изкуствените невронни мрежи като цяло не биха могли да разрешат нито един проблем, представляващ интерес. Те доказват, че моделът на перцептрон, бидейки прост линеен модел без скрити слоеве би могъл да решава само един вид проблеми, наречени линейно делими проблеми (linearly separable problems). Един пример за нелинейно делим проблем, с който те доказват тезата си е добилата известност като exclusive-or (XOR) логическа операция и неговото обобщение - откриване на паритет (the parity detection problem). В тази връзка Розенблат обмисля възможността за многослоест перцептрон, но по това време алгоритми за обучението на подобен модел не са били налице. Тази критика, в комбинация с нелепата смърт на Розенблат, който през 1971 загива в плавателен инцидент хвърля сянката на съмнение върху възможността за практическо приложение на изкуствените невронни мрежи в очите на учените, както и на техните благодетели. Финансирането за подобни проекти бива прекратено и много изследователи се насочват към по-конвенционални технологии от областта на изкуствения интелект. Във въведението на второто издание на „Перцептрон“ на Мински и Пейпърт от 1988 г. те оправдават своята критика по адрес на модела на Франк Розенблат и изкуствените невронни мрежи, твърдейки, че пренасочването на научните изследвания не е било “произволно отклонение, а необходим завој”. Също така споделя техен възглед, че е необходимо повече време, за да се развият адекватни идеи за представянето на знанията преди областта да може да продължи да се развива. Освен това, те твърдят, че отклоняването на ресурси от първоначалната идея е довело до много нови и силни идеи в областта на изкуствения интелект, като тези за Релационни бази данни (relational databases), рамки и производствени системи (frames and production systems), които от своя страна допринасят в много други области на научните изследвания, като в областта на психологията, науката за мозъка и приложните експертни системи. Те описват 70-те години като златен век за новата област на изследвания, но по ирония на съдбата това поставя края на втория период в развитието на изкуствените невронни мрежи и слага началото на т. нар. тъмна епоха.

Въпреки всичко, някои учени, като Дейвид Румелхарт (от Университета в Сан Диего) Стефан Гросберг (от Бостънския Университет), финландеца Теуво Кохонен и Кунихико Фукушима от Япония упорстват със своите опити и изследвания в областта на изкуствените невронни мрежи. Техните трудове виждат бял свят по време окачествено, като ренесансов период за областта, а именно през ранните 80 години на XX век. Джон

Хопфилд, виден учен от Калифорнийския Технически Институт представя своя статия в която предлага решаването на добре известната задача за пътуващия търговец с помощта на изкуствени невронни мрежи. Способността му да опише работата си от гледната точка на учен, подсилена с неговия авторитет стават предвестник на постепенното възстановяване и ново ускорение на научното развитие в тази област. В благодарение на него интересът към невронните мрежи се разраства и нови изследователи от множество области, вариращи от биолози и банкери до инженери и психолози се присъединяват към общността. За кулминация на този период се счита публикуването на първата от общо три части, книга наречена „Паралелно обработване на данни“ [34] през 1986, реферирана многократно от различни учени. В нея авторите препотвърждават предложения в по-ранна тяхна по-ранна публикация от 1986 година, алгоритъм с обратно разпространение на грешката, но този път той придобива необходимата популярност. Алгоритъмът с обратно разпространение на грешката преодолява някои от капаните на модела на перцептрон, посочени от Мински и Пейпърт, като позволява на модела на многослойния перцептрон да бъде обучен. Според Рипли [35] този алгоритъм първоначално е бил открит от Брайсън и Хо [36] през 1969 и Уербос [37], но не печели внимание, докато не бил преоткрит и популяризиран от Румелхарт. Според Ебърхарт и Добинс е трудно да се преувеличи влиянието, което книгата „Паралелна обработка на данни“ е имала върху изследванията и развойната дейност в областта на невронните мрежи. Те описват успеха на книгата в едно изречение: "В книгата е представено всичко практическо, което бихме желали да знаем за невронните мрежи през 1986 г., по разбираем, лесен за използване и интересен начин. В действителност, 1986 изглежда отбелязва момент от времето, в който "критична маса" от информация за невронните мрежи стана достъпна."

Модерната (настоящата) епоха в развитието на изкуствените невронни мрежи започва там, където книгите на Румелхарт и дават началото и бива наречена от Коун и Шарп [38] Neosconnectionism. В тази епоха те намират все по-голям брой търговски приложения, като същевременно продължава да се генерира ползотворен изследователски интерес от широко поле от дисциплини, което личи от големият брой на публикации и конференции на тази тема в същото време. Сейновски и Росенбург [39] разработват през 1987 г. базирана на изкуствени невронни мрежи програма за генериране на говор, способна да се самообучава, наречена „NETtalk“ и последвалата разработка на програма способна да разпознава ръкописен текст, използвана, пощенски кодове от Д. Мартин [40] през 1990 г. - подкрепят тезата, че невронните мрежи могат да бъдат впрегнати за решаването и обработката на трудни задачи. Значителните подобрения в областта на компютърните технологии, както и рязкото намаляване на стойността на мощните компютри, водят до развитието на приложения за изкуствените невронни мрежи, като универсална привлекателна и достъпна задача.

1.4.1 Опити за прогнозиране на капиталовите пазари с невронни мрежи

Идеята за използването на изкуствени невронни мрежи за прогнозиране е спомената за първи път от Ху и Руут [41] през 1964 г. с цел синоптични прогнози на времето, като заключението до което авторът достига е, че адаптивните системи (както авторът ги нарича), притежават способността да правят полезни прогнози за времето без да разбират напълно конкретната динамика или да разполагат с всички необходими параметри, които влияят на атмосферните условия. Липсата по онова време на методи за обучение на мрежите възпрепятства прилагането на тези методи за прогнозиране върху по-комплицирани проблеми. Но след представянето на алгоритъма с обратно разпространение на грешката през 80 те години на миналия век, Уербос [42] използва тази техника за обучение през 1988 и с негова помощ твърди, че невронните мрежи се

представят по-добре от регресионните методи и моделът на Бокс-Дженкинс при прогнозиране.

През последните три десетилетия, огромен брой изследвания са разработени в областта на невронните мрежи и по-специално тяхната способност да предсказват пазара на акции, като в следващите редове, представям кратко описание на някои от разгледаните трудове в хронологичен ред, както и кратко обобщение на направените констатации.

Може би първият труд в необятната област на прогнозирането на ценовите движения на пазарът на акции, чрез изкуствени невронни мрежи е дело на Хълбърт Уайт [43] през 1988 година, като в нея авторът цели да опровергае Хипотезата за ефективния пазар. В своята най-лека форма, хипотезата заявява, че движението на цените на активите представлява случайно блуждаене, което означава, че движението на цените е абсолютно невъзможно за отгатване предварително, на базата на публично достъпната информация, като пазарна цена и изтъргувания обем, историческите цени за този или друг клас активи и др. Целта на доклада е да илюстрира как търсенето на някакви закономерности, които могат да посочат бъдещото движение в цената на обикновените акции на IBM с помощта на изкуствени невронни мрежи и изменението в цената на акциите, като база данни, може да доведе до успех. Архитектурата на използваната мрежа е стандартната, с входящата информация, препредаване напред на към един скрит слой с пълна взаимосвързаност, с активацията на скрития слой предавана към изхода. Авторът използва за процеса на обучение мрежа с предавана напред информация, съставена от три слоя, пет входа и пет неврона в скрития слой за същия период от време. Изборът на пет скрити единици, представлява компромис в името на необходимостта да се включат достатъчно скрити единици, така че най-простите нелинейни закономерности да могат да бъдат открити чрез мрежата. Обучението, както вече бе споменато е извършено с помощта на алгоритъма с обратно разпространение на грешката, един от най-популярните и до ден днешен.

Сред първите опитали да прогнозираят индекси от акции на капиталовите пазари е Кимомото [44], който през 1990 заедно със своя екип използват изкуствени невронни мрежи, за да предскажат стойностите на един конкретен индекс на токийския фондов пазар (Tokyo Stock Exchange). Те използват няколко различни невронни мрежи, обучени да използват историческите данни за стойностите на няколко различни технически и икономически индикатора, за получаването на очакваната възвръщаемост от индекса Torix.

Камичо и Танигава [45] предлагат използването на на Елман - повтарящи се мрежи (Elman recurrent net) – разновидност на повтарящите се изкуствени невронни мрежи. Повтарящите се невронни мрежи са клас мрежи при който връзките между отделните неврони формират кръгова структура. Това оформя вътрешното състояние на мрежата по такъв начин, че да и позволява да проявява временно динамично поведение за целите на прогнозирането на цените на търгувани на борса акции, използвайки данни, като дневни минимум и максимум, както и цена на затваряне.

С времето, изследванията в областта нарастват експоненциално. Моделите се обогатяват от най-различни по вид и структура изкуствени невронни мрежи. Обектите на изследванията варират, като най-често срещани са и най-популярните и влиятелни индекси на търгувани акции, като Dow Jones Industrial Average, S&P 500, Nasdaq, Euro Stoxx 50, FTSE 100, DAX 30, Nikkei 225, CSI 300 и много други. Данните, използвани като входящи параметри в огромна част от случаите са ценова информация, данни за изтъргуванията обеми, технически показатели за търговията и др. В някои ситуации, авторите прибегват и до по-нестандартни данни, като анализ на протоколите от заседания на централни банки и дори настроеността в специализирани социални мрежи.

Не малко разработки се насочват към валутните пазари, като съвсем естествено и при тях основните валутни двойки - EUR/USD, EUR/JPY, USD/GBP, EUR/CHF и т.н. са предпочитани за прогнозиране, а входящите параметри варират от движението на други валутни двойки и макроикономически показатели до елементите за изчисляване на покупателната стойност на валутите. Пазарът на облигации, като един от най-тясно профилираните също е бил обект на изследване, но броят на трудовете в тази ниша е значително по-скромен. Същото важи и за този на деривати, като опции и фючърси предимно върху акции. Някои автори поглеждат и още по-далеч, като поставят за свой обект на прогнозиране цените на борсово търгуваните стоки и ценни метали от рода на петрол, злато, алуминий и пр. И разбира се, би било изненада ако тук не бъде споменато за изследвания на факторите които влияят и прогнозиране на цените на криптовалюти.

Прави впечатление, че в много по-голяма степен изследванията се провеждат от хора заети в научните среди за сметка на такива от инвестиционната общност, което според автора има своите положителни и отрицателни аспекти, както и напълно логични обяснения. На първо място, може съвсем основателно да се спекулира, че са налице разработки на модели за търговия на базата на техники от Изкуствения интелект, като невронните мрежи в рамките на не малко финансови организации начело с банки, инвестиционни фондове и брокерски къщи, които съвсем естествено не са достъпни за широката публика поради съвсем естествени и прозаични причини. Напълно нормално е ако някой е открил печеливша стратегия за търговия на финансовите пазари, да не е склонен да я сподели с никой друг. Излишно е да се смята че в при работата по подобни проекти се цели оборване на хипотези и други икономически постулати. Друг е въпросът, колко дълго би могло да бъде съхранена в рамките на една организация подобна информация без за нея да се разбере, особено при настоящата мобилност на труда и постоянни атаки срещу интелектуалната собственост. Авторът на дисертационният труд се е натъквал неколkokратно на разработки които дори са намерили приложение в някои общодостъпни платформи за търговия на финансовите пазари които обаче на са и не биха могли да бъдат изследвани в детайли. Следва само да бъде споменато, че те не са сред предпочитаните в инструментариума на т.нар. чартисти (привържениците на техническия анализ). На второ място, може да се посочи, че в никакъв случай на капиталовите пазари не липсват кадри с различен от икономически и финансов профил, напротив с напредването на технологиите дипломираните инженери са станали пословично предпочитани за големите инвестиционни фирми, но въпреки това социално-икономическата действителност не предлага особено големи стимули за разработване на научноизследователски трудове, с цел масово разпространение и обогатяване.

Средата за продуциране на изследвания в областта, все пак може да бъде окачествена като изключително благоприятна, основно заради развитието на технологията и по-специално на компютърните и информационни технологии. Достъпът до високопроизводителна изчислителна способност, дълго време е бил воден камък за напредъка на науката. Броят на програмите в които са заложени модели от изкуствения интелект, като невронни мрежи е нараснал значително в сравнение дори ако се разглежда период от по-малко от 10 години. Редно е да се спомене, че както във всяка друга област, немалка част от комерсиално предлагания софтуер не отговаря на очакванията и трудно би могла да бъде от полза за провеждането на качествени експерименти. Надеждни програмни продукти с история и дори традиции в годините, доказали своята ефективност, пак могат да бъдат прекалено скъпо струващи и да ограничат броя на хората, имащи достъп до тях.

Преди да продължим нататък е добре да направим бърз преглед на някои други модели за прогнозиране на капиталовите пазари от инструментариума на Изкуствения интелект.

1.5 Методи за прогнозиране на капиталовите пазари с подходи от изкуствения интелект

Алгоритъмът Дърво на решенията е добре познат в областта на Изкуствения интелект, използван за дейта майнинг машинно обучение за генериране на масиви от зания, които да насочват процеса по вземане на инвестиционни решения. Някои изследователи са използвали тази техника заради способността ѝ да разкрива зависимости и да предрича бъдещи стойности, както в малки така и в големи бази данни. Според кратко проучване, направено от С. Камли и колектив [46] резултатите, които този модел показва са представени в следната таблица:

Метод	Резултат	Автори
Дърво на решенията	85.94%	Чанг
Дърво на решенията	81%	Шайфи и кол.
Дърво на решенията	71%	Геп и кол.
Дърво на решенията	81%	Ву и кол.
Хибридно дърво на решенията	86%	Тсай и кол.
Дърво на решенията	82%	Рен и кол.
Дърво на решенията	65.41%	Тсаи и кол.
Хибридно дърво на решенията	88%	Ванг и кол.
Дърво на решенията	85.71%	Чен и кол.
Дърво на решенията	73.60%	Киркос и кол.
Хибридно дърво на решенията	80.24%	Барак и кол.

Таблица 1: Точност на прогнозиране с модели, основани на метода Дърво на решенията

Машина с поддържащи вектори, е метод за машинно самообучение, който се използва за регресия и класификация. При обучение с дадени примери, целта е да се построи модел, който да може да разпознае нови примери, и да ги причисли към съответния клас. Главната задача на този метод за машинно самообучение е да увеличи разликите между класовете възможно най-много. Принадлежи към семейството на линейните класификатори. Неговата успеваемост при прогнозиране на цени на акции е представена в следващата таблица:

Метод	Резултат	Автори
Машина с поддържащи вектори	79.40%	Чандавай и кол.
Машина с поддържащи вектори с Макроикономика	64%	Лахмири и кол.
Машина с поддържащи вектори	73%	Хуанга и кол.
Машина с поддържащи вектори	64.75%	Ким
Хибридна Машина с поддържащи вектори с Генетични алгоритми	61.73%	Чоундари и кол.
Хибридна Машина с поддържащи вектори с Генетични алгоритми	96.46%	Кхатиби и кол.
Машина с поддържащи вектори	91%	Циао и кол.
Хибридна Машина с поддържащи вектори с COM	80.26%	Циао и кол.
Машина с поддържащи вектори	72%	Сапанкевич и кол.
Машина с поддържащи вектори Полином	84.40%	Тимор и кол.

Таблица 2: Точност на прогнозиране с модели, основани на метода Машина с поддържащи вектори

Генетични алгоритми са клас адаптивни алгоритми за стохастична оптимизация, които включват търсене и итеративно оптимизиране на решението. За първи път са предложени от Х. Холанд [47]. Основната идея на генетичния алгоритъм е да се наподобява в опростен вид процеса на естествен отбор (селекция), с цел да се открие възможно най-добър алгоритъм за решаване на дадена задача. Първата стъпка е да се мутира, т.е. измени на случаен принцип, даден набор примерни програми. На втората стъпка се извършва селекция, което обичайно изисква сравняване на набора програми спрямо целева функция, още наричана фитнес функция. Процесът се повтаря докато се открие подходящо решение.

Съществуват голям брой различни видове генетични алгоритми и много степени на свобода при решаване с тях на оптимизационни задачи. Стъпката, включваща мутация, зависи както от това как са представени примерните програми, така и дали разработчикът ползва различни техники на кръстосване. Как точно се формулира фитнес функцията, спрямо стойностите на която решенията се сравняват, също е въпрос на избор на разработчика. Възможно е процесът да спре в локален оптимум на фитнес функцията и да пропусне глобалния. Едно от предимствата на генетичния алгоритъм е, че той не изисква фитнес функцията да е гладка, по причина че методът се базира на случайното търсене.

Метод	Резултат	Автори
Генетични алгоритми и Изкуствени невронни мрежи	94%	Жадев и кол.
Хибридни Генетични алгоритми и Машина с поддържащи вектори	84.57%	Ю и кол.
Генетични алгоритми	97%	Шета и кол.
Хибридни Генетични алгоритми и Радиална базова функция	85%	Маджи и кол.
Генетични алгоритми	95%	Самант и кол.
Генетични алгоритми	95%	Вей и кол.
Генетични алгоритми	77.84%	Секстън и кол.
Генетични алгоритми и GDMH Type	94%	Фалалхи и кол.
Хибридни Генетични алгоритми	93%	Хасан и кол.

Таблица 3: Точност на прогнозиране с модели, основани на метода Генетични алгоритми

Бейсови мрежи. Основната идея на БМ е да използва вероятностния подход за решаване на множеството проблеми в реалния свят, свързани с неопределеност. Това става чрез определянето на апостериорните маргинални разпределения на вероятностите при постъпване на наблюдения за някои от възлите в мрежата. В зависимост от вида на наблюдаваните възли двата крайни варианта на логическия извод с БМ са: прогнозиране – определение на вероятността на дадено събитие при наблюдаване на причини, и диагностициране – определяне на причината за наблюдаваните следствия. Този модел придоби толкова голяма популярност във финансите, като инструмент за моделиране, които имат способността да решават сложни проблеми, включващи анализ на вероятностите при несигурност. Те са вероятностни графични модели, които представляват набор от случайни променливи за даден проблем и се използват за представяне на вероятностната връзка между тях. Въпреки това, структурата на BN може да се използва за прогнозиране на възможността за увеличаване или спадане на пазарния индекс или цените на акциите във времето

Метод	Резултат	Автори
Бейсови мрежи	89%	Ванг и кол.
Бейсови мрежи	78.13%	Бола и кол.
Бейсови мрежи	92%	Насмосави и кол.
Бейсови мрежи	60%	Зуо и кол.
Бейсови мрежи	82.46%	Кита и кол.
Бейсови мрежи	76%	Богъл и кол.
Бейсови мрежи	86%	Пател и кол.

Таблица 4: Точност на прогнозиране с модели, основани на метода Бейсови мрежи

Други техники на Изкуствения интелект, използвани за прогнозиране са: Разсъждения на база прецеденти (case-based reasoning), Системи основани на правила (rule-based systems), Модели на база на размити множества (fuzzy models), Мултиагентни системи (multi-agent system), Обучение с утвърждение (reinforcement learning) и Хибридни системи (hybrid systems).

ГЛАВА II: АНАЛИЗ НА МЕТОДИТЕ ОСНОВАНИ НА НЕВРОННИ МРЕЖИ ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИТЕ ПАЗАРИ

2. Характеристики на невронната мрежа

Невроните в невронните мрежи са организирани в слоеве. Те могат да бъдат три вида: входящ, изходящ и скрит. Входящия слой получава информация само от външната среда, като на всеки неврон съответства входна (предсказваща) променлива. Във входния слой не се извършват никакви изчисления, той предава информацията към следващия слой. Изходящия слой произвежда крайните резултати, които се подават от мрежата навън от системата. Всеки неврон от изходящия слой, съответства на стойности на предсказваната променлива. Слоевете, разположени между входния и изходния слой се наричат скрити, тъй като те не влизат в директен контакт с външната среда. Скрытите слоеве се използват изцяло за аналитични цели. Тяхната функция е да открият съществуващите взаимовръзки между входните и изходните променливи.

Архитектурата, известна също като топология на една изкуствена невронна мрежа представлява нейната организация, а именно: брой слоеве, брой елементи (неврони) във всеки един от слоевете и начина, по който невроните са свързани помежду си.

Други присъщи характеристики са посоката на придвижване на информацията (посоката в която се извършват изчисленията, и типа на връзките между отделните елементи).

Невронна мрежа с повече от един слой претеглени неврони, съдържащи един или повече скрити слоеве се нарича многослойна невронна мрежа, като най-известния представител е многослойния перцептрон (multilayer perceptrons).

Различните информационни потоци водят до получаване на различни видове невронни мрежи. При мрежи с прав поток на (feedforward neural networks) информацията се придвижва само в една посока, от входящия слой през скритите слоеве към изходящия слой и няма обратни цикли. Невронни мрежи с обратна връзка (feedback neural networks) информацията се придвижва в двете посоки – от входящия към изходящия слой и обратно.

Ако всеки елемент от един слой е свързан със всички елементи от следващия слой, изкуствената невронна мрежа се нарича напълно взаимосвързана (totally interconnected); ако всеки елемент е свързан със всеки елемент от всеки слой, изкуствената невронна мрежа се нарича напълно свързана (totally connected).

При изграждането на изкуствени невронни мрежи потребителят или някакъв софтуер трябва да избере броя на възлите и скритите слоеве, активиращата функция, ограниченията за теглата. За тази задача не съществуват общовалидни правила и се налага да се експериментира с тези параметри.

След като очертахме основните характеристики на топологията на изкуствените невронни мрежи е време да се спрем на някои характерни особености при тяхното използване. Ще започнем с базата данни, които се използват за експериментите. За да бъде ефективно и успешно прилагането на модели с невронни мрежи, данните които ще се използват за тяхното обучение трябва да бъдат внимателно изследвани. Почти всеки модел, използван за прогнозиране на капиталовите пазари е чувствителен към липсващи, неточни или като цяло „шумни“ данни. Макар да са определяни като по-толерантни от повечето модели към шумни данни, невронните мрежи също търпят негативи от такива. Ако при биологичните им първообрази в човешкия мозък, големината на мрежата спомага справянето с подобни казуси, то би следвало да се предположи, че и при изкуствените невронни мрежи е валиден факта, че големината е от помощ в подобни ситуации. Добре е да бъде направена някаква предварителна подготовка на данните,

която да спомогне и улесни работата на мрежите, като например кодиране и трансформиране на променливите, както и намаляването на размера при наличие на прекалено големи обеми от данни с множество променливи.

Невронните мрежи работят само с цифрови променливи, а това налага превръщането на качествени показатели в цифри чрез преработка и създаване на номенклатури. Докато количествените променливи се представят с един неврон, то качествените променливи се представят в двоичен вид, чрез използването на няколко неврона за всяка променлива, като броя на невроните е равен на броя на стойностите, които приема всяка променлива.

Следващия етап в предварителната подготовка на данните или т. нар. data preprocessing е добре да бъде направен анализ за необходимост от трансформиране, например стандартизиране на входящите променливи, както и тяхното претегляне, за да се предотврати по-силното влияние на променливи с много високи стойности за сметка на такива с ниски стойности. Важен момент тук е, че ако мрежата е била обучена с трансформирани входни или изходни променливи, предсказаните резултати от нея бъдат възстановени по обратния ред на тяхната първоначална трансформация, за да могат да бъдат смислени.

Размер на входните променливи е много важен фактор, затова при много големи масиви с информация, а и за не толкова големи такива с цел подобряване на работата на мрежата, най-вече откъм скоростта на изчисление е добре да техният обем да бъде намален. Най-често се препоръчва това да бъде правено на база експертна оценка. Друг вариант е да бъдат използвани линейни и нелинейни комбинации на оригиналните променливи, като входни сигнали.

Както вече бе обяснено, архитектурата на изкуствената невронна мрежа е много важна за модела, затова при избора ѝ е необходимо да се подходи внимателно и да се прецени кой е най-подходящия вид, тъй като тя има съществено влияние върху точността на предсказване. Много от алгоритмите, работещи с невронни мрежи разполагат с функционалност за оптимизация на архитектурата в рамките на процеса по обучение, което е голямо предимство и води до значителна икономия на време, в сравнение с ръчното нагласяване от страна на експериментация.

След етапа на избор на архитектура на изкуствената невронна мрежа, основната цел при генерирането на модел за прогнозиране е намирането на теглата на връзките. Избрания алгоритъм изчислява теглата чрез използването на обучаваща извадка от наличните данни, като се минимизира функцията на грешката между реалните и предсказаните стойности. Този процес ще бъде разгледан в детайл след малко. Един от най-често използваните методи за обучение на изкуствени невронни мрежи е този с обратно разпространение (backpropagation).

Алгоритъмът за обучение чрез обратно разпространение работи по следния начин. Стойностите на входните променливи се предават чрез невроните на входа и произволно избрани първоначални тегла на връзките през скритите слоеве до изходния слой на мрежата, където се изчислява стойността на прогнозираната величина. Определя се грешката, получена в изходящите неврони, като разлика между изчислената и действителната стойности. След това грешката се предава от изходния слой, назад към скритите слоеве, като алгоритъмът настройва теглата на връзките с цел намаляване на генерираната от модела грешка. Този процес се повтаря, като целта е повторенията да продължат до изчезването на грешката или намирането на нейната минимална стойност. Всяко преминаване на през всички редове на обучаващата извадка се нарича епоха (epoch). В момента, когато грешката престане да намалява се счита, че невронната мрежа е обучена да открива закономерности в обучаващата извадка. Това твърдение има своите

условности и не означава че моделът може да бъде окачествен непременно като успешен, но засега ще се задоволим с този принцип.

За да се предотврати прекаленото нагаждане на невронната мрежа към данните от обучаващата извадка, процес известен като *overfitting*, и прекомерно обучение или „претрениране“ е нужно да се прецени кога да бъде прекратено обучението. В някои случаи се използва допълнителна, тестова извадка от базата данни с помощта на която, периодично се проверява невронната мрежа по време на обучението. Докато грешката намалява при проверката спрямо тази извадка – обучението не спира. Ако грешката при тестовата извадка се повиши – обучението спира, независимо от това, че същевременно грешката при обучаващата извадка може да продължава да пада. Това е елегантен начин да се избягва прекомерното обучение на невронната мрежа.


Причините за прекратяване на работата на обучаващия алгоритъм могат да бъдат различни: изразходването на определен изчислителен ресурс зададен предварително, когато функцията за грешката падне под някаква предварително зададена стойност, разликата между две последователни стойности падне под предварително зададен праг, грешката на предсказване по отношение на някаква подходяща (валидираща) съвкупност от данни, започва да нараства и др.

Няма изследване, което да е установило кой алгоритъм за обучение е най-добър. Работата на алгоритмите зависи и от задачата на изследването, прогнозираната цел и много други фактори, което се променя при различни задания.

2.1 Невродинамика

Процесите, протичащи в една изкуствена невронна мрежа ще бъдат формално и подробно описани в следващите редове. Неврон j с прагова стойност θ_j получава сигнали на входа, които ще бъдат представени като: $x=[x_1, x_2, \dots, x_n]$ от елементите на предишния слой, с който е свързан. Всеки от тези сигнал е свързан с тегло, съответно: $w_j=[w_1, w_2, \dots, w_n]$ което определя неговата важност. В зависимост от мястото му на инициране, всеки сигнал има различна важност. Биологичен пример за това може да бъде даден по следния начин: неврон, който се намира в зоната на визуалния кортекс може да присвои по-голямо тегло на сигнал идващ от съседни клетки отколкото на такъв идващ от по-отдалечени връзки. Това е причината поради която на различните сигнали се назначават различни тегла.

Невронът обработва едновременно входящите сигнали, техните тегла и праговата стойност чрез т. нар. комбинативна функция. Тази функция има за цел да произведе стойност, наречена потенциал или нетен входящ сигнал (*net input*). След това активиращата функция (*activation function*) трансформира потенциала в изходен сигнал. На Фигура 2 е показан модел на изкуствен неврон представен на Хайкин [24], както и неговата работа



Фигура 2 – Модел на невродинамика на Неврон j

Комбинативната функция обикновено е линейна, поради което потенциалът е претеглена сума на входящите сигнали, умножена по теглата на съответните връзки. Тази сума се сравнява със праговата стойност. Потенциалът на неврона j се определя по следния начин:

$$P_j = \sum_{i=1}^n (x_i w_{ij} - \theta_j) \quad (1)$$

За да се опрости изборът на потенциала, праговата стойност може да се абсорбира чрез добавянето на още един входящ сигнал с потенциална стойност $x_0 = -\theta_j$:

$$P_j = \sum_{i=0}^n (x_i w_{ij}) \quad (2)$$

Изходящия сигнал y_j на неврон j се получава чрез прибавяне на активиращата функция към потенциала P_j :

$$y_j = f(x, w_j) = f(P_j) = f\left(\sum_{i=0}^n x_i w_{ij}\right) \quad (3)$$

Величините x и w във функцията $f(x, w_j)$ са векторни величини.

При наличието на относително проста активираща, трансфера на енергия функция, въпросът е как точно да се изгради сложна изчислителна система. На първо място, невронът е способен да се обучава, което означава че теглата w_n за всеки идващ сигнал в неврона не са фиксирани и могат да бъдат променяни. Например ако един неврон получи информация от други неврони, че изходящия му сигнал y_j е твърде слаб

(силен), той може да нагласи така теглата на сигналите w_j , че да усилва силата на изходящия си сигнал (или обратното). На второ място, невроните са взаимно свързани и образуват сложни структури, приличащи на тези от човешкия мозък. По-опростените структури могат да разрешават по-прости проблеми, докато по-сложните структури са в състояние да решават по-сложни проблеми.

Един от най-важните елементи, които трябва да бъде определен при изграждане на модел с невронна мрежа е активиращата функция. Тя може да бъде най-различна, но сред най-често използваните активиращи функции са: линейна, сигмоидна и стъпаловидна.

Да предположим, че имаме проста невронна мрежа, като тази показана във Фигура 2, която се състои от три входящи елемента: A , B и C и един изходящ неврон y_1 . Връзките на входящите елементи с изходящия неврон са с тегла, съответно α , β и γ . За по-голяма яснота ще обозначим вътрешното съпротивление на изходящия неврон с реалното число c , графично представено като допълнително тегло, свързващо невронът сам със себе си и винаги генериращ сигнал равен на $1 \times c$. Входящите елементи A , B и C не притежават подобни постоянни връзки.

При така зададените връзки, за всяка стойност на A , B и C изходящата стойност на невронната мрежа ще бъде представена по следния начин:

$$y' = \alpha A + \beta B + \gamma C - c \quad (4)$$

Невронните мрежи са способни на да се учат (да променят вътрешните си тегла) на базата на предишен опит, или казано по друг начин изкуствените невронни мрежи прогнозираят параметри на базата на данни. Това означава, че на базата на набор от наблюдения за стойностите на променливите A , B и C и y е възможно да се обучи мрежата да разпознава y при дадени A , B и C . Това може да се илюстрира с проста системна процедура. Да речем, че разполагаме с наблюдения, стойностите на които са дадени в следната таблица:

A	B	C	y
- 1.0	1.0	-1.5	1.0
0.7	- 1.2	1.4	- 0.8
...	...	...	...
0.3	0.1	-0.9	- 0.3
1.2	- 1.5	0.3	0.7

Трябва да намерим връзка между зависимата променлива y и независимите променливи A , B и C . Като за начало, мрежата не разполага със знание за отношението помежду им. Затова теглата α , β , γ и c се определят да бъдат случайни числа. Така, подавайки тези стойности за A , B и C в мрежата, тя ще продуцира изходна стойност y_1 според уравнение 11.2. Резултатът от направеното изчисление е грешен, поради факта, че A , B и C са просто случайно избрани цифри, но вече можем да измерим тази грешка. Добро предположение за грешката E би била разликата между наблюдаваната (y) и прогнозираните от мрежата (y_1) стойности, осреднени за всички наблюдения. За тази цел може да се използва обикновената средна квадратична грешка:

$$E = \frac{1}{2N} \sum_{i=1}^N (y_i - y')^2 \quad (5)$$

После е необходимо да намерим стойности на α , β , γ и c , които минимизират средната квадратична грешка. Съществува лесен начин това да бъде направено, наречен градиентно спускане (gradient descent), който автоматично наглася теглата a , b , g и c по такъв начин, че гарантирано намалява цялостната грешка на мрежата E при всяка итерация. Тази процедура се прилага, като серия от последователни стъпки, в които входящите данни се подават в мрежата и се изчислява нова стойност на грешката. Това което трябва да се направи е да се пресметне с колко трябва да се променят теглата на всяка стъпка. С други думи, градиентното спускане задава въпроса: Ако е налице промяна в стойността на едно тегло, да речем α , до какъв ефект върху върху средната стойност на грешката води това? Или обратното, ако искаме да променим стойността на средната грешката E , каква трябва да бъде промяната, да речем в параметър α ? Може да се изрази, че при положение, че първоначалните стойности на теглата не са равни помежду си и не е равна на нула, промяна, по пропорционален на приноса им към общата стойност на грешката начин, ще доведе до нулева стойност на грешката на някакъв етап. Тази стойност на промяната във всяка стъпка за тегло α , например може да бъде изведена чрез диференциране на уравнения 1 и 2:

$$\Delta\alpha = -\lambda \frac{\partial E}{\partial a} = -\lambda \left(\left(\sum_{i=1}^N (y_i - y') A_i \right) \right) \quad (6)$$

Същото е валидно и за β , γ и c , параметъра λ се контролира ръчно от потребителя известен като скорост на обучение (learning rate) и регулира стойността с която се променя α по време на всяка стъпка.

Линейната (linear) функция, която изглежда по следния начин:

$$f(P_j) = \alpha + \beta P_j \quad (7)$$


Където P_j е реално число, а α и β са реални константи; в частния случай, когато $\alpha = 0$ и $\beta = 1$, се получава идентичната функция (identity function), която обикновено се използва когато моделът изисква изходният сигнал на неврона да е равен на неговото активиращо ниво (неговия потенциал);

Сигмоидалната функция (sigmoid), известна като S-образна активираща функция, е най-често използвана, тъй като е нелинейна и лесно разбираема. При нея изходния сигнал винаги е положителен и принадлежи на интервала $[0,1]$. Широко разпространено е мнението, че биологичните неврони не продуцират просто линейна трансформация на входящите сигнали на изхода си, а че модулират своя сигнал на изхода по такъв начин, че да прилича на сигмоидалната функция, т.е. колкото по-силен входен сигнал получават, толкова по-силен изпращат, но до някаква степен, след която изходящия започва експоненциално да намалява. Тази функция се определя по следния начин:

$$f(P_j) = \frac{1}{1 + e^{-\alpha P_j}} \quad (8)$$

$$f(x) = \frac{1}{1 + \exp(-X)} \quad (9)$$

Където α е положителен параметър, който определя наклона на функцията. Графиката на тази функция е следната:



Фигура 3 Сигмоидалната активираща функция

Стъпаловидна (stepwise) функция се изразява по следния начин:


$$f(P_j) = \begin{cases} \alpha, P_j \geq \theta_j \\ \beta, P_j < \theta_j \end{cases} \quad (10)$$

В този случай активиращата функция може да заема само две стойности в зависимост дали потенциалът превишава или не праговата стойност O_j . При $\alpha = 1$ и $\beta = 0$ и $O_j = 0$ получаваме т. нар. знакова активираща функция (sign activation function), която приема стойност 0 когато потенциалът е отрицателен и стойност +1, когато потенциалът е положителен;

Съществуват много други активиращи функции, използвани в моделите с изкуствени невронни мрежи, като една от тях е Гаусовата активираща функция:

$$f(x) = e^{\frac{-x^2}{2}} \quad (11)$$

Графично, тя изглежда по следния начин:




Фигура 4: Гаусова активираща функция

Съществуват и други функции, които са използвани, като активиращи в изкуствени невронни мрежи, една от които е функция от типа хиперболичен тангенс. За калкулирането на ефекта на грешката върху теглата на връзките в процеса на обратно разпространение на грешката в мрежата се използва производната на функцията за активиране. Производната на функцията хиперболичен тангенс има проста форма, точно както сигмоидалната функция. Това донякъде обяснява и честата ѝ употреба в модели на невронни мрежи, тя се изразява по следния начин:

$$\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (12)$$

Графично, тя изглежда по следния начин:



Фигура 5: Активираща функцията хиперболически тангенс

Тя е непрекъсната функция, която продуцира резултат за всяка стойност на x в мащаб $[-1;1]$.

2.2 Обучение на изкуствена невронна мрежа

На този етап ще бъдат разгледани предизвикателствата свързани с обучението на изкуствените невронни мрежи. Съществуват два подхода по отношение на обучението, дефинирани като контролирано обучение (supervised learning), неконтролирано обучение (unsupervised learning) и укрепващо или подсилващо обучение (reinforcement learning)[48].

Контролирано обучение (Supervised learning) е най-често срещания тип обучение на изкуствени невронни мрежи и изисква много шаблони, които да служат като образци. Всеки шаблон принадлежащ към комплект за обучение съдържа входни стойности със съответни желани изходни стойности (наричани също целеви стойности). След това мрежата се опитва да изчисли целевата стойност на базата на комплекта зададени входящи данни от всяка проба, чрез минимизиране на грешката на изхода си до достигане на целевия изход. Тя се опитва да направи това, като непрекъснато коригира теглата на връзките си чрез един повтарящ се процес на обучение, който на практика представлява трениране. Както вече бе споменато, най-често срещаният алгоритъм за обучение за подготовка на мрежата е алгоритъм с обратно разпространение на грешката.

Неконтролирано обучение (Unsupervised learning). Това понякога се нарича самостоятелно контролирано обучение и не се нуждае от конкретни стойности на изхода за провеждане на обучението. За всеки един от шаблоните подавани на входния слой на мрежата се допуска, че принадлежи към отделен клас параметри. По този начин, процесът на обучение се свежда до това да се остави мрежата да разкрие тези класове. Този метод не е толкова популярен колкото контролираното обучение и не е подходящ да се използва в този труд. Поради тази причина няма да бъде разглеждан по-нататък.

Усъвършенстващо обучение (Reinforcement learning) е хибриден метод за обучение поради факта, че на мрежата не са зададени целеви резултати, но в същото време мрежата се информира, ако изчислените изходни данни се движат в правилната

посока или не. Този метод също няма да бъде използван в този труд и няма да се разглежда в детайли.

За да бъде обучена една изкуствен невронна мрежа, това трябва да бъде направено с определена база данни, използвана като входящ параметър. Двата основни проблема свързани с този процес са:

- Дефинирането на базата данни, която да послужи за обучението или с други думи – формирането на обучаваща среда;
- Вземане на решение относно кой алгоритъм на обучение да бъде използван.

Един от най-важните фактори в процеса на изграждане на една изкуствена невронна мрежа е за какво точно ще бъде обучавана мрежата. Предвид специфичната насоченост на този труд, преимуществено ще бъдат разглеждани модели, конструирани да прогнозира движението в цените на финансови активи - акции, търгувани на регулиран пазар, на базата на историческата информация за движението в цената им и на някои технически индикатори за които ще бъдат обяснени в подробности в последствие. Едно от големите предизвикателства пред авторите обикновено е да определят кой или кои индикатори е най-удачно да се използват и каква да бъде композицията на входящите данни, използвани за обучение на мрежата. Входящите параметри може да бъдат, както необработени, така и обработени стойности на ценова информация за дадена акция или индекс от акции, дневно изменение в цената и обем на търговията. Също така може да се използват и производни данни и технически индикатори, които са изключително популярни сред участниците на капиталовите пазари, като пълзяща средна стойност, индикатори за тренд линии и индекс на относителна сила (RSI), показател за инерция или индикатори използвани от фундаменталния анализ от рода на вътрешна стойност на акция, счетоводна стойност на акция и различни съотношения, като цена/доход, печалба на акция, цена/продажби и други. Някои автори отиват твърде далеч в експериментирането с входящите параметри, като например Юуун и Суелс [49], които използват думи и фрази от тримесечните и годишните доклади до инвеститорите на ръководството и изпълнителните директори на компаниите. Входните данни трябва да позволят на невронната мрежа да обобщи поведението на капиталовия пазар – обект на интерес дори и да съдържат ограничени, непълни или излишни данни.

Обучението на изкуствени невронни мрежи включва представяне на входящи шаблони по начин, позволяващ на системата да минимизира своята грешка като същевременно ѝ даде възможност да подобрява своята ефективност. Алгоритъмът за обучение може да варира в зависимост от архитектурата на мрежата, но най-често срещаният алгоритъм за обучение използвани при прогнозиране на капиталови пазари с невронни мрежи е алгоритъмът с обратно разпространение на грешката. В тази част ще разгледаме някои от техниките за обучение и съпътстващите ги предизвикателства в някои разработени системи. Най-често срещаната архитектура при изкуствените невронни мрежи, ползвана за прогнозиране на цените на капиталови активи е тази на многослоева изкуствена невронна мрежа с право придвижване на информацията, обучена с алгоритъм с обратно разпространение на грешката.

Както вече бе обяснено, обратното разпространение на грешката по време на обучението на изкуствена невронна мрежа, представлява процеса по разпространение на грешка в системата в посока, обратна на придвижването на входящата информация, а именно от изходния им слой към входящия слой на мрежата. Изходящия слой на мрежата е единствения, който има целева стойност, с която да се сравнява продуцирания резултат и докато грешката се разпространява по обратният път към входящия слой чрез възлите, тежестите на връзките между отделните неврони се променят. Обучението продължава докато грешката в теглата е достатъчно незначителна, за да бъде приета. Интересно е да

се отбележи, че видът на активизиращата функция, използвана във възлите на невронната мрежа може да бъде фактор относно вида на данните, с които се обучава мрежата. Така например, според Климасаускас [50], сигмоидалната функция работи най-добре когато мрежата се обучава за поведението на средните стойности, докато хиперболичната функция върши най-добра работа, когато се обучава за девиация от средната стойност.

Основният проблем при обучението на изкуствени невронни мрежи е решението кога да се спре процеса на обучение. Тъй като способността да се правят обобщения е от фундаментално значение за способността на мрежите да прогнозира бъдещите цени на финансови активи, прекомерното обучение, прекомерно нагаждане или прекаляването с процеса на трениране е сериозен проблем. Прекомерното нагаждане се случва, когато системата запамети определени тенденции или шаблон и по този начин започне да губи способността си да обобщава. Това е важен фактор за системите за прогнозиране, тъй като тяхната цел е да отгатват бъдещо движение или да обобщават на базата на входящи данни, които „виждат“ за първи път. Прекомерно обучение може да бъде причинено и от наличието на прекалено много скрити слоеве или провеждането на твърде много повторения на цикъла на обучение, включващ преминаване на данните през мрежата и калибрирането на теглата на връзките отново и отново, чрез обратното разпространение на грешката. Много често авторите на неуспешни експерименти с изкуствени невронни мрежи отбелязват, че слабите им резултати се дължат на т. нар. „претрениране“. За щастие подобни незадоволителни резултати могат да бъдат избегнати, чрез провеждане на процедури по изпитване и, или кръстосано валидиране. Процедурата по изпитване на резултатите на невронната мрежа включва обучение на мрежата на база по-голямата част от използвания шаблон (стойността варира в широки граници, но обикновено е около 90%) и последващо изпитване на невронната мрежа с остатъка от шаблона. Представянето на мрежата в така наречената тестова среда, или тестовия набор от данни е добър показател за способността и да се справя и обобщава данни, на базата на които не е била обучена. Ако резултатът от тестовата среда е незадоволителен, конфигурацията на мрежата или параметрите на обучението и могат да бъдат променени, след което се провежда нов цикъл по обучение докато постигнатите резултати не се подобрят до степен, приемлива за изследователя. Кръстосаното валидиране е подобен на процеса на изпитване на резултатите на невронната мрежа, като се различава по това че входящите данни са разделени на „ k “-сетове. Системата се обучава на базата на $k-1$ сетове и е изпитана на оставащите сетове k - пъти с помощта на различен тестови сет всеки път. Прилагането на тази процедура би следвало да намали опасността от претрениране, да предостави приблизителна стойност на мрежовата грешка и да спомогне определянето на оптималната мрежова конфигурация. В благодарение на тази процедура провеждащия експеримент притежава известна степен на контрол над процеса на обучение на мрежата, което му позволява да избегне неприятностите, свързани с претрениране.

Друга важна подробност е самото количество на данните за обучение. В идеалния случай е желателно за обучението да се използва максимално голяма база данни, с която системата може да бъде обучена по приемлив начин. Добре е да бъдат използвани достатъчно голям набор от данни, поради факта че някои шаблони на поведение не могат да бъдат открити в малки бази данни. Въпреки това, често е трудно да се добие достатъчно голям масив от данни – пълни и с коректни стойности. Освен това обучението на основата на големи бази данни може да бъде много изискващо време и изчислителна мощ процес, а при определени условия би могло да завърши с това че мрежата да „научи“ нежелана и ненужна информация. Така например, данните за фондовия пазар са зависими от времето. Затова следва да бъдат представени достатъчно данни, така че невронната мрежа да може да улови повечето от тенденциите, но от друга

страна твърде стари данни биха могли да подведат мрежата и тя да научи модели и фактори, които вече не са важни и ценни. Макар и напредъка в изчислителната мощност на компютрите, достъпни до широката общественост да е значителен в последните десетилетия и обемът на обработваните данни да е нараснал многократно, необходимото време за провеждане на експерименти от този род продължава да стои като ограничение. Обикновено броя на скритите слоеве е от съществено значение за скоростта на обработка на информацията.

Накрая, съществува голямо разнообразие от мрежови архитектури, използвани при прогнозирането на капиталовите пазари, които не използват алгоритъма с обратно разпространение на грешката. Независимо от използваните в тях организация, алгоритъм и брой скрити слоеве, моделите с изкуствени невронни мрежи остават много чувствителни към т. нар. прекомерно обучение, така че техники като кръстосаното валидиране и изпитване на продуцираните резултати следва да се използват за спомагане намаляването на грешката на системата.

2.3 Организации на невронни мрежи

Както вече бе споменато най-често използваната структура на изкуствена невронна мрежа за прогнозирането на инструментите, търгувани на капиталовите пазари е тази обратно разпространение на грешката. Въпреки това, далеч не е необичайно използването на други архитектури, като например с генетични алгоритми, повтарящи се мрежи (recurrent networks), модулни мрежи (modular networks), Мрежи с обща регресия (general regression networks), мрежи с радиално базирана функция (radial basis function networks) и много други. В тази част ще бъдат разгледани тези алтернативи, както и тяхното представяне. Мрежата с обратно разпространение на грешката е най-често използвана, защото предлага добра възможност за генерализация и е сравнително лесна за прилагане. Въпреки че при нея може да бъде трудно да се определи оптималните конфигурация и мрежови параметри, тази мрежа предлага много добри резултати, когато бъде обучена по подходящ начин.

Архитектура с повтарящи се мрежи (recurrent networks) е една от популярните и широко разпространени, с която се правят модели за прогнозиране на капиталовите пазари. Основната идея, залегнала в използването и е тази, че в исторически план определени ценови движения могат да се повтарят отново и отново във времето, като по този начин се превръщат в шаблонни. При наличието на подобни силно зависещи от времето тенденции може да се обоснове, че мрежа запаметяваща предходни входящи данни или обратни връзки и предходни изходни данни би имала по-голям успех в разпознаването на подобни шаблони. Съществува голямо разнообразие от подобни мрежи, притежаващи повтарящи се връзки между отделните слоеве или запомнящи предходни изходящи данни с цел използването им като нов сет от входящи данни за системата, което разширява измерението на входното пространство. Представянето на този род мрежи се намира за задоволително от литературата в областта. Например, самоорганизиращата се мрежа е проектирана да изгради нелинеен, хаотичен модел, прогнозиращ цени на акции на базата на входящи данни, включващи цените на акциите и изтъргувания обем. Отличителни белези на данните автоматично се изваждат и класифицират от системата. Ползата от използването на самоорганизиращи се невронни мрежи е, че те намалява броят на функции (скритите възли), необходими за класифицирането на отделни шаблони, както и че организирането на мрежата се развива автоматично по време на нейното обучение. Повтарящите се мрежи предлагат някои предимства пред тези с обратно разпространение на грешката, тъй като тяхната функция за запаметяване може да се използва за извличане на времевите зависимости в данните и

по този начин да се подобрят техните прогнози. По-сложните модели могат да бъдат полезни за намаляване на грешките или конфигуриране на структурата на мрежата, но те често са значително по-сложни за обучение и анализиране.

Модулната невронна мрежа е изкуствена невронна мрежа, изградена от поредица от независими невронни мрежи, които са моделирани от някакъв посредник. Всяка независима невронна мрежа служи като модул и работи чрез свои отделни входи, за да реши някаква подзадача от общата задача, която мрежата се опитва да разреши. Посредникът взема изходните данни на всеки от модулите и ги преработва, за да се получи обща изходяща информация на мрежата като цяло. Посредникът приема само изходните данни на отделните модули, но не реагира, нито сигнализира по друг начин на модулите, като в същото време отделните модули не взаимодействат един с друг.

Едно от основните предимства на модулната невронна мрежа е способността и да редуцира голяма и тежка невронна мрежа до по-малка такава с по-лесно управляеми компоненти. Съществуват практически задачи, които са неразрешими за една невронна мрежа когато размерът и се увеличава над определено ниво. Ползите от използването на модулна невронна мрежа вместо една единствена, всеобхватна невронна мрежа са множество и могат ще бъдат изложени в следващите редове.

С напредъка в изследванията на изкуствените невронни мрежи е уместно да се повтори, че те използват своето биологично вдъхновение за да имитират сегментацията и модулизацията срещана в мозъка. Така например, човешкия мозък разделя сложни задачи като визуалното възприятие на множество подзадачи.

Някои задачи, с които мозъка се занимава, като зрението поддържат определена йерархия от подмрежи, въпреки че не е известно дали съществува някакъв посредник, който свързва тези отделни процеси заедно в по-голям мащаб. Тъй като задачите нарастват и стават по-абстрактни, изолирането и раздробяването между отделните модули се срива и те започват да комуникират помежду си назад и напред. В този аспект аналогията на модулната невронна мрежа с биологичния си модел е или непълна или неадекватна.

Тъй като времето за изчисляване зависи от броя на възлите и техните връзки, всяко увеличение на тези компоненти ще има драстични последици върху времето за обработка.

По отношение на ефективността на мрежата, потенциалното нарастване на връзките е много трудно да бъде успешно адресиране от тази мрежова архитектура, тъй като при добавяне на нови възли към мрежата времето за изчисляване нараства значително. Колкото повече се разделя на отделни части голямата задача за решаване, възможните връзки, които всеки възел може да осъществява се лимитират, по този начин може да се предполага, че подзадачите ще бъдат разрешавани по-ефективно отколкото ако се търси разрешаване на задачата. като едно цяло и наведнъж.

При процеса на обучение, възможностите на голяма невронна мрежа да моделира няколко параметъра може да пострада от смущения, дължащи се на факта че новите данни могат драматично да променят съществуващите връзки или просто да послужат за объркването им. С някаква предвидимост на подзадачите, които трябва да бъдат решени, всяка невронна мрежа може да бъде специално адаптирана за изпълнението им. Това означава, че алгоритъма за обучение и тренировъчните данни използвани за всяка подмрежа може да са уникални и да бъдат изпълнени много по-бързо. В голямата си част това се дължи на намаляването на възможните комбинации от интересни фактори, паралелно с намаляването на броят входящите данни.

Независимо от това дали голямата невронна мрежа е биологична или изкуствена тя остава силно податлива на смущения и повреди във всеки един от нейните възли. Чрез разделянето на подзадачи, смущенията и сриговете са много по-лесни за локализиране и

диагностициране и техният ефект върху другите подмрежи се елиминира, поради факта че всяка една е независима от другите.

Невронните мрежи с радиална базирана функция (radial basis function networks) представляват модел на изкуствена невронна мрежа използваща радиалната базирана функция за активираща функция. Изходните данни на мрежата са линейна комбинация от радиални базисни функции на входовете и невронни параметри. Мрежите с радиална базисна функция имат много приложения, включително функция за сближаване (апроксимация), прогнозиране на времеви редове, класификация и система за контрол. За първи път те са формулирани в научна статия през 1988 година от Брумхед и Лоу [51].

Този тип невронни мрежи обикновено се обучават от алгоритъма на две стъпки, като първата стъпка включва избора на център-векторите на радиалната базисна функция в скрития слой. Това от своя страна може да бъде изпълнено по няколко начина – центровете могат да бъдат случайно извадени от даден сет с примери или могат да бъдат определени, използвайки групиране от типа k -средни величини (Класификация без обучение, чиято цел е да се оформят естествени групи въз основа на много признаци едновременно. Той принадлежи към науката за Обработка на сигнали - Signal processing, имаща за цел да разделя N наблюдения в K клъстери, в които всяко наблюдение принадлежи на клъстера с точност до средната стойност, която служи за прототип на клъстера). Трябва да се има предвид, че тази стъпка от процеса не се провежда без надзор. Втората стъпка е използването на обратно разпространение на грешката за фина настройка на всички параметри на невронната мрежа с радиалната базова функция.

Мрежи с обща регресия (general regression networks). Те много наподобяват невронната мрежа с радиалната базова функция и заедно с пробабилитичната невронна мрежа се предлага и развива от Спетч [52] през 1990 година. Този клас мрежова структура има няколко характеристики, сред които: способност да се обучава бързо, да работи опростено и по недвусмислен начин с алгоритъма на обучение и да дискриминира редки и откъснати от множеството и съдържащи грешки наблюдения. Както предполага самото им име, мрежата с обща регресия е в състояние да доближава всяка арбитражна функция (arbitrary function) на базата на исторически данни. В основата на тази функция стои теорията за нелинейната регресия (kernel regression), чиято цел е да направи оценка на очакваната стойност на изходящите при даден набор от входящи данни на базата на нелинейно отношение. Въпреки че мрежата осигурява многовариантен вектор на изхода, който не губи способност да обобщава, описанието на логиката по която действа мрежата с обща регресия е опростена до случай с единствен статистически изход.

2.4 Определяне на броя на невроните и скритите слоеве

Броят на входните и изходните неврони се определя по усмотрение на провеждащия експеримента и зависи от прогнозираната величина/и и спецификата на данните с които се разполага. За тази задача не съществуват общовалидни правила и се налага да се експериментира с тези параметри. Въпреки това, съществуват някои основни принципи предложени от различни изследователи накратко изредени в следващите редове:

- Ших [53] твърди, че топологията на невронни мрежи трябва да има пирамидална форма, за да може да има най-голям брой неврони в първоначалните слоеве за сметка на по-малък брой неврони в по-късните им фази. Той предлага броя на невроните в всеки слой да бъде приблизително средна величина между броя на предишните и следващите слоеве, не повече от два пъти броя на предходния слой. Или конкретно: ако една мрежа притежава 12 неврона в предходния слой и 3

неврона в последващия, тя би следвало да има от 6 до 24 неврона в слоя намиращ се по средата.

- Според Азоф [54], груб ориентир базиран на теоретични условия известни като измерение Вапник-Червоненкис, препоръчва броят на данните за обучение да бъде най-малко десет пъти този на тежестите. Също така цитира теорема на Хетч-Нилсен и Липман [55], която казва че невронна мрежа с един скрит слой и $2N+1$ скрити неврона е достатъчна за N входящи данни.
- Лоурънс [56] предлага следната формула за определяне на броя на скритите неврони, необходими в една мрежа:

*Брой скрити неврони = факти за обучението * толерантността към грешки.*

Където: фактите за обучението се отнасят до данни принадлежащи на шаблоните, използвани за обучението, докато толерантността към грешка се отнася за нивото на акуратност, желания или допустим диапазон на грешката.

- Баум и Хауслер [57] предлагат броя на невроните в скрития слой да бъде калкулиран посредством следната формула:

$$j = \frac{me}{n+z} \quad (13)$$

Където: j е броя неврони в скрития слой, m е броя на данните в обучаващия сет, e е толерантността към грешка, n е броя на входовете на мрежата и z е броя на изходите.

Последните две правила са много сходни и лесно могат да се окажат безсмислени в случаите, когато допустимата грешка е значително по-малка от броя на единичните данни в обучаващия сет. Така например, ако броят на единиците данни в обучаващия сет е 100, а толерантността към грешки е 0,001, броят на скрити неврони ще бъде 0.1, в което няма смисъл. Докато предложеното от Баум и Хауслер ще даде дори още по-нисък резултат. Въпреки това повечето изследователи не са убедени, че правила от типа „преценка на око“ могат да бъдат от полза. Те оспорват тезата, че може да се определи добра архитектура на изкуствена невронна мрежа само от броя на входовете и изходите.

Според The Neural Network FAQ [58] може да се предложи един метод наречен „Ранно спиране“ или „спряна тренировка“ при което се използват по-голям брой скрити неврони с много ниска скорост на обучение и с малки, произволни първоначални стойности на теглата. Нивото на грешката спрямо валидиращ сет от данни се изчислява периодично по време на обучението. Подобен метод за ранно спиране се използва в разработването на приложения на изкуствени невронни мрежи за прогнозиране на различни финансови проблеми, като валутна търговия. Въпреки това, тези, мрежи не използват твърде много скрити единици. Вместо това, те започват с малък брой скрити неврони, като броят им се увеличава постепенно само ако изкуствената невронна мрежа не показва признаци на обучение (грешката спада маргинално). По този начин проблемът с т. нар. прекомерно напасване към входните данни, при който обикновено се получава при наличието на повече тегла отколкото данни за обучение може да бъде избегнат. И все пак се смята, че използването на прекалено големи изкуствени невронни мрежи води до намаляване на грешката при обучение и прогнозиране.

При изграждането на изкуствени невронни мрежи потребителят или някакъв софтуер трябва да избере броя на възлите и скритите слоеве, активиращата функция, ограниченията за теглата. И тук както при определянето на броя на невроните, на автора не е известно да има всепризнато правило за определянето им в зависимост от целите на модела.

Според някои автори, в това число Маккулаг и Нелдер [59], скритите слоеве може и да не са необходими на изкуствените невронни мрежи, за да изпълняват заданията си. Те откриват че линейните и генерализиращи линейни модели могат да бъдат полезни в голямо разнообразие от приложения. Те предполагат, че дори ако функцията, която трябва да се научи е нелинейна, то прост линейен модел ще бъде в състояние да работи по-добре отколкото един сложен нелинеен модел, при условие че има достатъчно данни или твърде много шум, за да се изчисли по точно нелинейността.

Многослойния перцептрон, използващ стъпаловидна функция за активиране, прагова или от тип Хевисайд (оригинално използвана от Розенблат при разработения от него перцептрон) се нуждаят от два скрити слоя, за да развият напълно способностите си да генерализират, според Зонтаг [60], докато при ползване на някоя от широкия кръг от продължаващи нелинейни функции се изисква само един скрит слой с произволно голям брой скрити неврони, за да се постигне универсално апроксимиране, както е описана от Хорник [61] през 1993.

2.5 Накратко за характеристиките на невронната мрежа

В тази глава бяха разгледани основните аспекти на изкуствените невронни мрежи, започвайки от тяхната същност и биологичен произход, основни характеристики и архитектура. Бе обърнато внимание на важността на предварителната обработка на данните и на разделянето им на обучаващи и изпитващи сетове. В подробности бе описана невродинамиката, както на ниво единичен неврон, така и за целия модел на изкуствена невронна мрежа. Акцент бе поставен върху наличието на различни техники за обучение, набора от активиращи функции и важността на алгоритмите за обучение. Видовете организация на невронните мрежи бе нагледно очертана и бяха набелязани конкретни видове, които да бъдат изпитани за целите на настоящия дисертационен труд. Накрая бях прегледани различни начини за определяне на броя на скритите слоеве и неврони в моделите с изкуствени невронни мрежи. Авторът смята, че по този начин е поставена основата за изграждане на модели от изкуствени невронни мрежи с които да се направи експеримент за прогнозиране на стойностите на индексите от българския фондов пазар. Методологията е важен елемент от изграждането на успешни системи за прогнозиране, но ще бъдат необходими допълнителни проучвания в сферата на пазарите на финансови инструменти, обект на предвиждане от различни експериментатори през годините. Както се твърди в някои от традиционните методи за отгатване на финансовите пазари, знанието от миналото може да бъде използвано за отгатване на бъдещето и в опит да бъде направено точно това, е добре да се разгледа еволюцията на експериментите във времето.

2.6 Многослоен перцептрон

Както бе споменато в предишните раздели, многослойния перцептрон (наричан още многослоеста мрежа със предаване на информацията напред) е продължение на модела на перцептрона с добавен един или повече скрит слой, с нелинейна активираща функция в скритите неврони. Многослойния перцептрон с един скрит слой е универсален

апроксиматор и е в състояние да научи всяка функция, която е непрекъсната и определена по компактна област (което означава, че входовете имат определени граници, вместо да нямат граници на това, което могат да бъдат), както и функции, които се състоят от краен сбор от точки. Според Мастърс [62] многослойните перцептрони могат да научат много от функциите, които не отговарят на изброените вече критерии. Поспециално прекъснати такива, могат да бъдат толерирани теоретично и функции, които не притежават компактна подкрепа (като нормално разпределени, случайни променливи) могат да бъдат научени от мрежа с един скрит слой при определени условия. Той посочва, че на практика втори скрит слой се изисква само ако функцията която е непрекъсната има няколко прекъсвания. Най-често срещаната причина многослойния перцептрон да се провали при процеса на обучение е нарушаването на допускането за компактност на домейна, т.е. входовете не са ограничени. Той заключава, че ако има проблем с обучението на многослойния перцептрон, то той не се дължи на самия модел, а по-скоро на недостатъчно обучение, или недостатъчен брой неврони, недостатъчен брой шаблони за обучение или опит да се научи недетерминирана функция.

2.6.1 Обучаващи алгоритми

Съществуват множество обучаващи алгоритми, които намират широка употреба в изследванията с изкуствени невронни мрежи, но тук няма да се спирам на изброяването и обяснението на всички, а само на тези които имат пряко отношение към дисертационния труд и са използвани в него или са били реално обсъждани алтернативи.

Първите разгледани ще бъдат делта правилото и неговото обобщение алгоритъма с обратно разпространение на грешката. Процедурата по обучение трябва да включва избора на теглата $\{w_{ij}\}$ и „наклона“ $\{\theta_j\}$, които обикновено се приемат за еднакви [63], като се минимизира общата квадратична грешка – E :

$$E = \frac{1}{2} \sum_p \|t^p - o^p\|^2 \quad (14)$$

където o^p е изходът за вход x^p , t^p е целевия изход, а p индексира шаблона на тренировъчния сет. И двата алгоритъма са част от т.нар gradient descent rule, което представлява математически подход за намаляване на грешката между действителните и целевите резултати. Това се осъществява като се модифицират теглата със стойност, пропорционална на първата производна на стойността на грешката по отношение на теглото. Метафорично представено, този процес е равносителен на това да се опитва да се стигне до най-ниската стойност по повърхността на грешката от нейната върхна точка без да се попадне в някоя клисура.

2.6.2 Делта правилото / Метод на най-малките квадрати Least Mean Squares (LMS)

Алгоритъмът на най-малките квадрати е предложен от Уидрол и Хоф, като е известен и като правилото Уидрол-Хоф [65] през 1960 г., когато те представят модел наречен ADALINE (Adaptive Linear), който наподобява модела на перцептрон с разликата, че той притежава един единствен изходящ неврон и активационната функция на изхода представлява дискретна биполярна функция, продуцираща стойности 1 или -1. Този алгоритъм превъзхожда използвания от Розенблат при перцептрона по отношение на скоростта, но неговия недостатък е че не може да бъде използван при мрежи със скрити слоеве.

В по-голяма част от литературата се твърди, че Делта правилото и Метода на най-малките квадрати са едно и също – Нелсен и Илингуорд [66] и те до голяма степен са, по отношение на формулата за регулиране на теглата, която е следната:

$$\Delta w_{ij} = \eta \delta_j x_i \quad (15)$$

където η е скоростта на обучение ($0 < \eta < 1$), а δ_j е грешката при неврон j .

От друга страна, са налице и противоположни мнения, като например на Фу [67], който твърди, че правилото на най-малките квадрати, открито от Станфордския професор Бернард Уидрол и неговия докторант Тед Хоф се различава от Делта правилото при ползването им в модел на перцептрон по начина по който се изчислява стойността на грешката за актуализиране на теглата.

При Делта правилото формулата може да се представи като:

$$\delta_j = T_j - O_j \quad (16)$$

При методът на най-малките квадрати от друга тя е:

$$\delta_j = T_j - \sum w_{ij} x_j \quad (17)$$

Методът на най-малките квадрати може да се изрази и като правило за градиентно спускане (gradient descent rule). Ако заменим O^p с $X_p W^p$ в представеното по-горе уравнение (1)

$$E = \frac{1}{2} \sum_p \|t^p - X_p W^p\|^2 \quad (18)$$

където X_p е входящ вектор, а W^p вектора на теглата. След това техниката за нарастване и спускане (gradient descent technique) минимизира грешката, посредством коригиране на теглата:

$$\Delta W = -\eta \frac{\delta E}{\delta W} \quad (19)$$


където η е скоростта на обучение.

where η is the learning rate. След Equation 3-13 and Equation 3-14, правилото за най-малките квадрати може да бъде пренаписано:

$$\Delta W = -\eta (t_p - X_p W^p) X_p \quad (20)$$

2.6.3 Обратното разпространение на грешката / Генерализираното делта правило

Алгоритъма с обратно разпространение на грешката представлява генерализация на Делта правилото, като по този начин може да работи успешно при изкуствени невронни мрежи със скрити слоеве. Той е далеч най-популярния и широко разпространен алгоритъм сред изследователите заради простия си дизайн и лекота на приложение.



Фигура 6 – Обрато разпространение на грешка за единичен неврoн j .

Този модел ще послужи за обяснение на алгоритъма с обратно разпространение на грешката, който се използва главно при многослойните перцептрони. За по голяма яснота, тук ще бъде използван единичния неврoн, но методологията остава непроменена и за по комплицирани модели.

Алгоритъма с обратно разпространение на грешката включва процес на обучение на два етапа: Преминаване на информацията напред и преминаване на информацията назад през изкуствената невронна мрежа. При преминаването напред изходната информация O_j се калкулира на базата на набор от входяща информация (шаблони за обучение) X_i :

$$O_j = g(h_j) = f(h_j \theta_j) \quad (21)$$

където

$$h_j = \sum_{i=1}^i w_{ij} x_j \quad (22)$$

Откъдето следва че:

$$O_j = f\left(\sum_{i=1}^i w_{ij} x_i, \theta_j\right) \quad (23)$$

Където f е нелинейната трансферна функция, например сигмоидалната функция, θ_j е праговата стойност за неврон j , x_i е входа от неврон i , а w_{ij} е теглото свързано с връзката от неврон i със неврон j . След като изходната информация от мрежата бъде изчислена, обучаващия алгоритъм се прилага от изхода към невроните, намиращи се във вътрешността на мрежата, като по обратния път коригира всички тегла на връзките на мрежата, които е необходимо. Процесът на коригиране на теглата Δw_{ij} е като този при правилото за най-малките квадрати:

$$\Delta w = \eta \delta_j x_i \quad (24)$$

където η е скоростта на обучение ($0 < \eta < 1$) и δ_j е грешката при неврон j ;

$$\delta_j = e_j(O_j)1 - O_j = \left(\sum \delta_k w_k\right) O_j(1 - O_j) \quad (25)$$

за неврони в скрития слой, където k е неврона, който получава изходящата информация от неврон в скрития слой. Корекциите се добавят след това, към предишните стойности:

Стойност на новото тегло:

$$w_{ij} = w'_{ij} + \Delta w_{ij} \quad (26)$$

където w'_{ij} е стойността на предишното тегло.

Методът с градиентно спускане The gradient descent method е податлив на опасността да „попадне в пропаст“, или по-точно да попадне в локален минимум. Образно казано, ако повърхността на грешката е във формата на купа – този алгоритъм може да се окачестви като топче, опитващо се да се търколи се от върха на тази купа към нейното дъно (глобалния минимум на стойността на грешката или решението). Ако топчето се търкаля прекалено бързо, то то ще подмине дъното и ще започне да се изкачва по срещуположната повърхност на купата. Скоростта на спускане може да се контролира с термина скорост на обучение - h . От друга страна, ако скоростта на обучение е настроена да бъде много малка стойност, топчето ще се спусне много по-бавно и това ще означава по-дълго време за обучение. Повърхността на грешката на типичен проблем, обикновено не е гладка купа, а може да съдържа джобове и неравности, където топчето може да попадне. По този начин терминът инерция, често се добавя към основния метод

на „навигиране“ на топчето, за да се избягва движението прекаленото движение назад и напред по повърхността на грешката.

Процесът на коригиране на теглата ще се трансформира до:

$$\Delta w_{ij} = (1 - M)\eta\delta_j x_i + M(w'_{ij} - w''_{ij}) \quad (27)$$

където M е терминът инерцията и w''_{ij} е теглото преди предходното тегло w'_{ij} . Терминът инерция позволява промяната на теглата да се задържи за няколко цикъла на регулиране. Трябва да се отбележи, че ако M е определен като нула, то уравнението се връща към уравнение 3-6.

За да се облекчи проблема с локалния минимум, към мрежата често се добавят „случайни шумове“. Целта на терминът шум е, образно казано да „раздруса“ модела така че той да успее да излезе от локалния минимум, в който е изпаднал. По този повод Фалман [68] отбелязва, че изкуствените невронни мрежи с обратно разпространение на грешката могат да попаднат и често попадат в локални минимума, но те са необходими, за да може да се разреши даден проблем. Или казано с други думи, попадането в локален минимум може да бъде достатъчно за решаването на някои проблеми, и намирането на глобален минимум не е необходимо.

2.6.4 Продуктивност на изкуствените невронни мрежи

Когато става дума за предвиждане на капиталовите пазари, продуктивността на изкуствена невронна мрежа най-често се измерва чрез това колко точно тя прогнозира посоката на пазара. За добро представяне се считат случаите, в които мрежата се справя по-добре от вече изброените традиционни методи за прогнозиране и с по-малко грешки. Също така, някои автори изграждат модели с изкуствени невронни мрежи с цел да подложат на изпитание Хипотезата за ефективните пазари, разработена от проф. Еужен Фама - важен спорен момент за инвеститорите. Ако невронна мрежа може да се представя системно по-добре от пазара или предсказва посоката на движение с необходимата точност, валидността на хипотезата е под въпрос. Други невронни мрежи се разработват, за да се представят по-успешно от статистическите и регресионни техники.

2.7 Използване на невронни мрежи за прогнозиране на капиталовите пазари

Като една от най-добре познатите софт компютинг техники, изкуствените невронни мрежи са обект на детайлно изучаване и приложение през последните десетилетия. Разработките на алгоритъма с обратно-разпространение на грешката, използван за многослойни перцептрони допринасят за ускорението на развитието на други алгоритми за обучение на невронни мрежи мрежи от друг тип, като такива с радиална базова функция (radial basis function neural networks), повтарящи се мрежи (recurrent networks), мрежи с обратна връзка (feedback networks), и Кохентни не-надзиравани самоорганизиращи се мрежи (unsupervised Kohonen self-organizing networks) и много други. Всички изброени и особено многослойният перцептрон, използващ алгоритъм с обратно разпространение на грешката са си спечелили признание с приложенията им в различни научни и инженерни области. За да се ускори процеса на

обучение, както и да бъде преодоляно прекомерното обучение на база на входящите данни в модела (data over-fitting), са проведени множество изследвания за подобряване на алгоритъма с обратно разпространение на грешката. Освен това, в моделите с изкуствени невронни мрежи са добавени и интегрирани други методи от областта на изкуствения интелект, като размита логика и Уейвлет трансформации, за да се подобри способността за тълкуване и моделиране на данни и да се избегне субективността при работата на алгоритъма на обучение.

През години са се появявали нови методи за прогнозиране, като например този с поддържащи вектори (support vector machines), представляващи високопроизводителни, контролирани, генерализиращи, линейни класификатори, конкуриращи изкуствените невронни мрежи. Предимството на тази техника, е че предлага добра точност с по-малка изчислителна мощност. Предпочитани за експерименти по предсказания в среда на голям обем от данни, като класификация на текст или разпознаване на реч и разбираше, за прогнозиране на финансови пазари, но изследванията, които ги използват отстъпват значително на тези с изкуствени невронни мрежи. Напоследък използването им намалява значително за разлика от това на невронните мрежи.

В днешни дни огромни количества капитал се търгуват чрез фондовите пазари по целия свят. Националните икономики са силно свързани и силно повлияни от представянето на техните пазари на акции. Освен това, пазарите са все по-достъпни за инвестиране, не само за стратегически инвеститори, но и за обикновените хора, както това се дължи главно на техническите иновации и развитието на новите технологии, но също така и на разхлабването на регулаторната рамка от страна на властите. Редно е да се отбележи, че напоследък, последната тенденция по-скоро се обръща в посока на свръх регулиране, но всичко това по скоро забавя нарастването отколкото да намалява броя и обемите капитал, участващ на пазара. Следователно те не се влияят само от макроикономически и макроикономически данни, но и от всекидневния живот по един по-директен начин. Затова пазарите представляват механизъм, който има важни и преки социални въздействия. Една от основните характеристики, която всички фондови пазари притежават е несигурността, свързана с бъдещото им състояние в краткосрочен и дългосрочен план. Тази неизвестност е нежелана от инвеститора, но също така и неизбежна, когато фондовия пазар се разглежда като инвестиционна възможност. Най-доброто, което индивидуалните и институционалните инвеститори могат да направят, е да се опитат да намалят тази несигурност. Процесът за осъществяването на това начинание се нарича прогнозиране, предвиждане или отгатване на бъдещото движение на пазара.

2.7.1 Невронните мрежи и прогнозирането на капиталови пазари през годините

Концепцията за изкуствена невронна мрежа не е нещо ново в науката. Предложена за първ път е от Уорън Маккълук и Уолтър Питс 1943 г. [29]. След това от службата за военноморски изследвания на САЩ възлагат на Франк Розенблат [31] през 1957 г. да изгради алгоритъма перцептрон. Еднослойният перцептрон не оправдава очакванията, тъй като успява да улови само ограничени линейни тенденции. Подреждането на два или повече слоя неврони (в невронна мрежа с предавана напред информация или многослоен перцептрон) подобрява резултатите, но все още не може да предвиди успешно функцията XOR.

Марвин Мински и Сеймор Паперт в своята книга, озаглавена Перцептрони [33] показват, че не е възможно тези мрежи да моделират проста XOR функция през 1969 г. В продължение на много години цитирането на книгата задържа напредъка в областта на

изкуствените невронни мрежи. Едва през 80-те години моделът започва да се радва на нови активни изследвания, а през 2012 г. Джефри Хинтън демонстрира използването на генерализиран алгоритъм за обратно разпространение за обучение на многослойни невронни мрежи в софтуерния конкурс Imagenet, който успява да даде нов тласък напред на тази област.

Новаторските промени в обработката на данни в средата на 2010 г. също оказват своето влияние. Процесорната мощност на един ядрен процесор вече се е увеличила многократно в сравнение с 80-те години, а появата на Интернет на устройствата прави възможно голямо събиране на данни, което осигурява така необходимите данни за обучение за невронни мрежи. Така може да бъде обобщена, макар и съвсем накратко „голямата картина“ в полето на невронните мрежи. Във следващите редове ще бъде проследен пътя на тази може би най-популярна техника на изкуствения интелект в средата на капиталовите пазари и на вечния стремеж за тяхното разбиране, отгатване и надхитряне.

Идеята за използването на изкуствени невронни мрежи за прогнозиране е спомената за първи път от Ху [41] през 1964 г. с цел синоптични прогнози на времето, като заключението до което авторът достига е, че адаптивните системи (както авторът ги нарича), притежават способността да правят полезни прогнози за времето без да разбират напълно конкретната динамика или да разполагат с всички необходими параметри, които влияят на атмосферните условия. Липсата по онова време на методи за обучение на мрежите възпрепятства прилагането на тези методи за прогнозиране върху по-сложни проблеми. Но след представянето на алгоритъма с обратно разпространение на грешката през 80-те години на миналия век, Уербос използва тази техника за обучение през 1988 и с негова помощ твърди, че невронните мрежи се представят по-добре от регресионните методи и моделът на Бокс-Дженкинс при прогнозиране [37].

През последните четири десетилетия, огромен брой изследвания са разработени в областта на невронните мрежи и по-специално тяхната способност да предсказват пазара на акции, като в следващите редове, ще бъде представено кратко описание на някои от разгледаните трудове в хронологичен ред, както и обобщение на направените констатации.

2.7.2 Анализ на резултатите от разгледаните трудове

1 Може би първият труд в необятната област на прогнозирането на ценовите движения на пазарът на акции, чрез изкуствени невронни мрежи е дело на Хълбърт Уайт през 1988 [43] година, като в нея авторът цели да опровергае Хипотезата за ефективния пазар. В своята най-лека форма, хипотезата заявява, че движението на цените на активите представлява случайно блуждаене, което означава, че движението на цените е абсолютно невъзможно за отгатване предварително, на базата на публично достъпната информация, като пазарна цена и изтъргувания обем, историческите цени за този или друг клас активи и др. Целта на доклада е да илюстрира как търсенето на някакви закономерности, които могат да посочат бъдещото движение в цената на обикновените акции на IBM с помощта на изкуствени невронни мрежи и изменението в цената на акциите, като база данни, може да доведе до успех. Необходимостта да се справи с характерните черти на времеви серии от икономическите данни подчертава важността на статистическите заключения и също така изисква модифициране на методите за обучение на невронните мрежи, които могат да се определят за полезни при прилагане в най-общи условия. Целевата променлива предизвикваща интерес в това изследване е дневната възвръщаемост от държането на една обикновена акция на IBM. От наличните данни за 5 000 бр. дневна възвръщаемост, е избран шаблон състоящ се от 1 000 бр.

дневни изменения за процеса на обучение, в комбинация с два образци от по 500 изменения, респективно от преди и след периода използван за обучение, които да послужат за оценка на натрупаните от изкуствената невронна мрежа знания. Шаблонът, използван при обучението обхваща период от 1974 до 1978 година, докато периодите използвани за оценка включвали стойностите, заключени между 1972 г. и 1974 г. и 1978 г. до 1980 г. Архитектурата на използваната мрежа била стандартната: с входящата информация, предавана напред към един скрит слой с пълна взаимосвързаност. Авторът използва за процеса на обучение мрежа с предавана напред информация, съставена от три слоя: пет входа и пет неврона в скрития слой. Изборът на пет скрити единици, представлява компромис в името на необходимостта да се включат достатъчно скрити единици, така че най-простите нелинейни закономерности да могат да бъдат открити чрез мрежата. Обучението, както вече бе споменато е извършено с помощта на алгоритъма с обратно разпространение на грешката, един от най-популярните и до ден днешен. За да може да докаже тезата си, че хипотезата за Ефективния Пазар е статистически опровергана, Уайт провежда експеримент да прогнозира извън периода на трениране (out-of-sample). Този експеримент се извършва за период от 500 дни преди и след периода използван за обучение, като наблюдаваната корелация е от -0.699 за последващия и 0.0751 за предхождащия период. В крайна сметка авторът прави заключението, че подобни резултати не представляват убедително статистическо доказателство срещу Хипотезата за ефективния пазар. Резултатите от експеримента, проведен върху данните на обучението са определени като прекалено оптимистични. Като причина се посочва или прекомерното нагаждане (over-fitting), тъй както случайните флуктуации са били погрешно разпознати като нелинейни движения или проведено обучение със мимолетни характеристики (характеристики, присъствали в процеса на обучение, които в следствие изчезват). Заключението е категорично: „настоящата изкуствена невронна мрежа не е машина за пари!“ Сред изложените задачи за бъдещо изследване и разработка са да се модифицира структурата на невронната мрежа, така че да позволява използването на допълнителни входящи данни, като изтъргуван обем, цените на други акции, водещи икономически индикатори, други макроикономически данни и други. Друго ценно заключение е това, че използваните методи за оптимизация са на практика локални и въпреки, че крайните тегла са определени, като такива даващи най-добър резултат, няма гаранции, че е бил намерен глобалния минимум на грешката. Затова се предлагат глобални методи за оптимизация, като за предпочитане били симулирано закаляване и генетични алгоритми. Доказателства срещу Хипотезата за ефективните пазари не са достатъчни, за да я оборят защото използваната мрежа не разполага с достатъчно генерализираща мощност.

2 Сред първите опитали да прогнозират индекси от акции на капиталовите пазари е Кимото[44], който през 1990 заедно със своя екип използват изкуствени невронни мрежи, за да предскажат стойностите на един конкретен индекс на токийския фондов пазар (Tokyo Stock Exchange). Те използват няколко различни невронни мрежи, обучени да използват историческите данни за стойностите на няколко различни технически и икономически индикатора за получаването на очакваната възвръщаемост от индекса Торіх. Самият индекс, Торіх, по времето в което се е провеждал експеримента се състои от акциите на компаниите, регистрирани за търговия на най-представителния сегмент на токийската фондова борса, претеглени на база общия брой на акциите на компанията. В днешни дни, след реформа протекла между 2005 и 2006 година, теглото на компаниите в индекса вече се определя на база на броя акции на разположение за търговия или т. нар. free float. Използваните технически и икономически индикатори са векторна крива (индикатор за моментното състояние на пазара), изтъргуван обем, стойност на основния лихвен процент, определен от Японската централна банка, валутния курс на японската

йна спрямо щатския долар и стойността на индекса Dow Jones Industrial Average на Нюйоркската фондова борса. Целевия резултат от невронната мрежа представлява претеглената сума на логаритъма на съотношението между стойността на индекса в края на седмицата t спрямо стойността му в момент $t-1$.

$$r_t = \ln \frac{TOPIX_t}{TOPIX_{t-1}} \quad (28)$$

Като желан резултат е претеглената сума на r_t за няколко последователни седмици. Самия процес по извличане на данни не е обяснен в подробности в статията, освен че за премахването на някои несъответствия в базите данни се използва логаритмична функция преди нормализирането им. Авторите претендират, че използването на претегления сбор от продуцираните резултати на невронните мрежи способства за редуцирането на грешката, особено когато се прогнозира очакваната доходност за хоризонт от няколко седмици напред. На базата на предложенията на мрежите за доходността на акциите, е разработен модел за генериране на сигнали за покупка и продажба и се доказва, че той се представя много по-добре от обикновена пасивна стратегия – „купи и задръж“ при която не се търси нарастване чрез постоянна покупка и продажба на подценени и надценени акции, а се разчита на дългосрочното представяне на предварително подбрани такива.

3 Камичо и Танигава [45] (1990) предлагат използването на на Елман - повтарящи се мрежи (Elman recurrent net) – разновидност на повтарящите се изкуствени невронни мрежи. Това са клас мрежи, при който връзките между отделните неврони формират кръгова структура. Това оформя вътрешното състояние на мрежата по такъв начин, че да и позволява да проявява временно динамично поведение за целите на прогнозирането на цените на търгувани на борса акции, използвайки данни, като дневни минимум и максимум, както и цена на затваряне. За разлика от такива с право препредаване на информацията, повтарящи се изкуствени невронни мрежи могат да използват тяхната вътрешна памет за обработката на произволни последователности от входяща информация. Използван е метод за извличане на триъгълни формирания от графиките на движението на цените, на акциите на базата на параметрите: най-висока и най-ниска цена за деня, както и цена на затваряне. Според техническия анализ триъгълниците се считат за знак за предстоящо нарастване на цената на финансови активи, след появата на графиката на локален максимум и минимум и след продължителен период на осцилация около дадено ниво. Моделът залага на обучена невронна мрежа да разпознава триъгълни формации в ценовата графика. Данните за модела са образувани от цените на всички компании, които са част от индекса. Самите триъгълни формирания не са дефинирани от система базирана на правила. Експертна система наречена „четец на графики“ извлича 16 триъгълника, като 15 от тях се използват за обучение на мрежата, а един за изпитването ѝ. Резултатите от работата на екипа са, че е разработен метод за оценка на повтарящи се мрежи, както и метод за разпознаване на триангуларни формирания на графиката на цените на акциите, а заключението е, че те са приложими за намаляване на несъответстващите шаблони.

4 Матсуба [68] използва за експеримента си невронна мрежа с разпространение на информацията назад, като я захранва с последните n на брой стойности на борсов индекс и последващите $N-n$ стойности, като изходни. По същество това представлява предсказване от типа „стъпка напред“, така че ако индекса за $n^{\text{тия}}$ ден е означен с X_n , тогава входовете са X_1, X_2, X_n , а изходите са $X_{n+1}, X_{n+2}, \dots, X_N$. Когато подобни невронни мрежи се обучат, всякаква корелация между стойността на индекса за $n+1$ при използване на $N^{\text{тия}}$ ден ще бъде пренебрегната. За да се увери че това не може да се случи,

мрежата се обучава с грешки, измежду стойностите на желаните и действителните изходни стойности в допълнение на n входящите данни. При това положение, тези грешки биха били $X_{n-1} - Y_{n+1} \dots$, където Y е изхода на невронната мрежа. По време на процеса на обучение, грешката ще клони към нула и допълнителните входящи данни няма да бъдат необходими във фазата на тестване. В този труд авторът използва две невронни мрежи, една за научаване на глобалните тенденции и характеристики и друга за локалните, по-незначими и малки флуктуации. Заключение е, че методът дава по-добри резултати от невронните мрежи без обратна връзка, когато се прилага за прогнозиране на дългосрочните цени на акциите.

5 В своя труд, Б. Фрейслибен [69] използва няколко варианта на невронна мрежа с разпространение на информацията направо и обратно разпространение на грешката, като за нейното обучение използва данни от миналото и настоящето, за прогнозирането на един по-малко популярен индекс на немския пазар - FAZ Index. Използваните входящи данни включват, стойностите на пълзящите средни на индекса за 5 и 10 седмици назад, числено диференцирана стойност на FAZ Index, и стойността на нейната пълзяща средна, настоящата стойност на популярен индекс, измерващ представянето на пазара на дългови ценни книжа и неговата диференцирана стойност и обменния курс на валутната двойка щатски долар и немска марка и неговата диференцирана стойност. Интересен факт, е че той определя числовите редове от финансови данни, като полу-хаотични. На база на тези входящи параметри се прави опит да се предвиди стойността на индекса FAZ за седмица напред. Изкуствената невронна мрежа се обучава на база на данните за последните M седмици, след което се тества на базата на следващите L седмици, като M е наречен тренировъчен прозорец, а L е наречен тестови прозорец. След всяка успешна прогноза, т. нар. прозорци биват премествани с една стъпка напред и мрежата бива обучавана наново. Експериментът е проведен на три различни вида невронни мрежи, като за всяка се използват различни входни данни, една от които се състои само от последните 10 стойности на индекса. Наблюденията показват, че мрежата, хранена с данни от технически индикатори се е представила по-добре от тази, която е тренирана само с предишните стойности на индекса FAZ. Провежда се нормализиране на данните за обучението, което се извършва, за да се запазят данните в диапазона от 0.1 до 0.9, но не се разкрива по детайлна спецификация на метода за нормализация.

6 И отново, К. Камичо и Т. Танигава [70] използват модел с повтарящи се мрежи, който е по-ефективен за изчисленията, който те предлагат при разработването на система за прогнозиране на цените на акциите Токийската фондова борса. Те наричат този модел „допълнително обучение“ (supplementary learning) или актуализиране на куп (batch updating), като при него теглата се актуализират на основата на сумата на всички грешки от всички използвани шаблони. Всеки изходен възел в системата притежава асоцииран праг на толерантност към грешка и грешките се разпространяват назад, само ако надвишат този праг на толерантност. Тази процедура води до промяна само на грешките, което прави процесът по-бърз и способен да се справи с по-големи количества данни. Също така, системата автоматично променя константите направени по време на обучението, въз основа на данни за количеството за грешката, които се разпространяват обратно, назад в мрежата.

Системата за прогнозиране на акциите на Токийската фондова борса е обучавана на база на данни за повече от 33 месеца и също така използва движеща се (динамична) симулация по време на обучение. При движещата се симулация се прави предсказване, докато се преместват целевите периоди на обучение и прогнозиране. Например, първоначално системата е обучена на базата на данни от Януари, тествани на база данни за Февруари, след което те се използват за прогнозиране на данните за Март. В следващата итерация, системата се обучава на база данните от Февруари, тества се на

база данните за Март, след което прогнозира данните за Април. По този начин системата непрекъснато се актуализира на базата на най-новите данни и нейното представяне се подобрява. Токийската система за прогнозиране на цените на акциите представлява модулна невронна мрежа, състояща се от четири мрежи с обратно разпространение на грешката, обучение по различни елементи от данните. Системата за търговия с акции на Токийската фондова борса се представя по добре от прилагането на стратегия за купуване и държане, както и от индексът на акции на борсата в Токио.

7 П. Уинстън – професор от Масачузетски технологичен институт и директор на лабораторията по Изкуствен интелект, издава своята книга – Изкуствен интелект, в която прави подробно описание на това какво могат и какво не могат изкуствените невронни мрежи, по-късно той разработва самоорганизираща се система [71], която използва комбинация от технически, адаптивни (базирани на ограничените функции за поддръжка - limited support functions) и статистически индикатори, като входни данни, с цел да бъдат прогнозираны цени на акции. Той използва две самоорганизиращи се невронни мрежи в тандем, като едната избира и открива характеристики на данните, а другата извършва класификация на шаблоните. Но прекомерното обучение (overfitting) и затрудненията в обучението са все още проблеми в тази организация. Разработена е и интересна хибридна мрежова архитектура, която комбинира невронна мрежа с експертна система. Невронната мрежа се използваше за прогнозиране на бъдещите цени на акциите и генериране на сигнали за търговия. Експертната система използва своите правила за управление и формулирани техники за търговия, за да валидира сигналите за търговия, генерирани от невронната мрежа. Ако данните, генерирани на изхода нарушат предварително определени принципи, експертната система може да наложи вето върху изходните данни на невронната мрежа, но няма да генерира собствен резултат. Тази архитектура има потенциал, защото съчетава нелинейното прогнозиране на невронните мрежи с базираното на правила познание на експертните системи. По този начин, комбинацията от двете системи предлага отлични познания и ефективност. Няма правилна организация на мрежата. В този труд се прави заключението, че всяка мрежова архитектура има свои собствени предимства и недостатъци. Мрежите с обратно разпространение на грешката са често срещани, защото постигат добри резултати, но често са трудни за обучение и конфигуриране. Повтарящите се мрежи предлагат някои предимства пред мрежите с обратно разпространение на грешката, тъй като тяхната способност да запамятават може да се използва за извличане на зависимости в данните от времето и по този начин да се подобри прогнозирането. По-сложните модели могат да бъдат полезни за намаляване на грешките или проблемите с конфигурацията на мрежите, но често са по-сложни за обучение и анализ.

8 Според Е. М. Азоф [72], изкуствената невронна мрежа е компютърна програма, която може да разпознава шаблони в бази данни, като може да се учи от това разпознаване и да прави прогнози за бъдещи периоди. По това време били налице малко над 20 търговски програми, използващи технологията с изкуствени невронни мрежи, предназначени за използване на финансовите пазари, и съществували някои забележителни научни статии за тяхното успешно прилагане. Въпреки това, подобно на всяка друга компютърна програма, невронните мрежи са толкова добри, колкото данните, с които се хранят и заданията, които им се поставят. Правилното използване на невронната мрежа включва разходване на време, както за тяхното точно разбиране, така и за „почистване“ на самите данни, чрез премахване на грешки, предварителна обработка и последваща обработка. Неговата книга предоставя знанията, които се изискват за правилното проектиране и използване на изкуствените невронни мрежи в прогнозирането на финансовите пазари - с акцент върху търговията с фючърси.

9 В техния труд от 1995 година, И. Кастра и М. Бойд [73] представят едно не техническо въведение при проектирането на изкуствените невронни мрежи за прогнозиране, използвайки икономически данни под формата на времеви редове. Процедурата за проектиране на модел е разделена на осем стъпки: Избор на променлива, Събиране на данни, Предварителна обработка на данни, Комплекти за обучение, изпитване и валидиране, Парадигми на невронни мрежи, Критерии за оценка, Обучение на изкуствената невронна мрежа и Изпълнение. Авторите опитват да прогнозират изтъргуваните месечни обеми на фючърсите върху шест стоки на Стоковата борса на Уинипег (Winnipeg Commodity Exchange – WCE). Три са основните изводи, до които авторите достигат: първият е, че изследователите трябва да разполагат с ресурси и търпение да експериментират главно поради природата на финансовите пазари. Втората е, че софтуерът на който се използват изкуствените невронни мрежи трябва да позволи автоматизация на често повтарящи се процедури, като тестване напред, оптимизация на неврони в скрития слой и тестване на комбинации от входящи променливи, или чрез директно програмиране, или чрез използване на партии от скриптови файлове. И трети, изследователят трябва да поддържа добър набор от записи, които да изброяват всички параметри за всяка тествана мрежа, тъй като всеки параметър може да се окаже причина за значителна промяна в представянето на невронните мрежи. Резултатите от работата на изследователите показват, че изкуствените невронни мрежи са способни да прогнозират до девет месеца напред във времето и се справят по добре от наивен модел в четири от шестте разгледани стоки.

10 В статията си от 1996 г. Р. Дж. Ван Ейдън [74] показва изчерпателна примерна система от невронни мрежи, наричана системата JSE, моделирала работата на фондовата борса в Йоханесбург. Тази система се опитва да получи цялостен поглед върху пазарната среда, като използва необработени данни, чрез използването на 63 показателя от различни категории. Посочените 63 стойности, служещи за входящи данни на системата могат да бъдат разделени на следните класове, като броя на индикаторите във всеки клас е показан в скоби:

- Фундаментални индикатори (3) – изтъргуван обем, доходност и съотношението цена на акция/печалба на компанията
- Технически индикатори (17) – пълзящи средни, обемни тенденции и др.
- Индекси на JSE (20) – пазарни индикатори за няколко различни сектора: златодобивен, други метали и др.
- Международни индекси (9) – индекса Dow Jones Industrial Average и др.
- Цената на златото и на валутите (3)
- Лихвените равнища (4)
- Икономически индикатори (4) – износ, внос и др.

Системата JSE нормализира всички данни в диапазона $[-1,1]$. Нормализираните данни са обща характеристика във всички системи, тъй като невронните мрежи обикновено използват входни данни в диапазона $[0,1]$ или $[-1,1]$. Авторът отбелязва също и факта, че намаляването на някои входни данни може да е трудна задача, особено ако данните не са числови. Системата JSE представлява мрежа с обратно разпространение на грешката, създадена чрез генетичен алгоритъм. Генетичният алгоритъм позволява автоматичното проектиране на дизайна на невронната мрежа. В този случай, заключението е че оптималната мрежова конфигурация е с един скрит слой с 21 неврона. Генетичните алгоритми са особено полезни, когато размерите на входа са големи. Те позволяват на мрежовите разработчици да автоматизират конфигурацията на мрежата, без да разчитат на евристични или на методи от тип проба - грешка.

Системата JSE е обучена на базата на 455 броя образци и е тествана на 51 броя образци. Всеки модел съответства на входните стойности за даден ден. Системата JSE демонстрира превъзхождащо представяне и според автора, успява да предскаже пазарната посока, така че да отхвърли теорията за ефективния пазар.

11 Също през 1996 година, Чанг и колектив [75], използват изкуствена невронна мрежа с обратно разпространение на грешката, за да прогнозира нетната стойност на активите в края на годината на взаимни фондове, с помощта на исторически данни на икономически индикатори. Те сравняват тези резултати с резултатите, получени при използване на традиционните иконометрични техники, като линейни и нелинейни регресионни анализи и заключават, че изкуствената невронна мрежа "значително превъзхожда регресионните методи", при ограничени наличие на данни.

12 Куо и колектив [76] признават, че качествените фактори, като политически събития винаги играят много важна роля в определянето на настроенията на фондовия пазар и предлагат интелигентна система за прогнозиране на фондовия пазар, която включва както количествени, така и качествени фактори. Моделът, разработен от тях включва събиране на фактори, модел за количествените показатели, чрез изкуствена невронна мрежа, модел за обработка на качествените с помощта на размития модел Delphi и модел за интеграция на решения отново на базата на изкуствена невронна мрежа. Те прилагат своя модел на фондовия пазар в Тайван.

13 В своя публикация, Ким и Чун [77], използват прецизна пробабилистична изкуствена невронна мрежа, наречена масирана вероятностна мрежа, с която правят опит да предскажат бъдещото движение на индекс на фондов пазар. Основната характеристика на техния модел е, че той продуцира прогноза за множество дискретни стойности, а не един биполярен изход. Като част от изследването си, те използват таблица с грешки, която служи като база за сравнение между изкуствена невронна мрежа с право разпространение на информацията и обратно разпространение на грешката, пробабилистична изкуствена невронна мрежа, масирана вероятностна мрежа, повтарящи се невронни мрежи и прецедентно базирани разсъждения. Те стигат до заключението, че в конкретния случай, прецедентно базираните разсъждения, са склонни да се представят по-добре от всички изброени изкуствени невронни мрежи.

14 През 1999 Айкен и Бсад [78] използват изкуствена невронна мрежа с право разпространение на информацията, обучени с генетичен алгоритъм, за да прогнозират доходността до падеж по тримесечните съкровищни облигации на САЩ. Тяхното заключение е, че невронните мрежи могат да се използват за предвиждане на т. нар Yield To Maturity (YTM).

15 През 1999, Еделман [79] и екипа му изследват използването на набор от идентично структурирани и независимо обучени една от друга невронни мрежи, за да идентифицират възможностите за арбитраж при широкия австралийския индекс: Australian All Ordinary Index. Решенията за покупко продажба се вземат въз основа на единодушен консенсус от страна на набор от десет мрежи и техните прогнози за стойността на Австралийския индекс. Индекса на Шарп се използва за оценка на резултатите, излизащи извън пределите на извадката на база на която са обучавани мрежите. Емпиричните резултати показват, че търгуването на база на прогнозите за изкуствените невронни мрежи надминава стратегията на покупка и държане, както и т. нар. „наивни прогнози". Те стигат до заключението, че надеждността на прогнозите за мрежите, а от там и на резултатите от търговията е драстично подобрена чрез използването на праговете при търгуването и груповия подход.

16 През 1999 г. Тамаmano [80] използвал модел, базиран на невронни мрежи и размита логика, за да предрече бъдещата цена на най-голямата Тайландска банка с държавно участие в капитала. За входящи параметри са използвани настоящата цената

на акциите при затваряне, за последните три месеца и коефициентите за рентабилност: Възвръщаемост на активите (ROA), Възвръщаемост на собствения капитал (ROE) и съотношението цена/печалба. Моделът продуцира на изхода си цените на акциите за следващите три месеца. Той прави заключението, че „нево-размитата“ архитектура е способна да разпознае общите характеристики на фондовия пазар по-бързо и по-точно от основния алгоритъм с обратно разпространение на грешката. Също така тя би могла да предвиди инвестиционни възможности по време на икономическата криза, когато статистическите подходи не дават задоволителни резултати.

17 Трафалис [81] използва изкуствена невронна мрежа с право разпространяване на информацията и обратно разпространение на грешката и седмичните изменения на 14 индикатора, за да прогнозира промяната в цената на индекса S&P 500 през следващата седмица. В допълнение, той разработва и успешно прилага методология за предварителна обработка на използваните данни която включва диференциране и нормализиране на данните. Той твърди, че е разумно да се очаква, че по-софистициран метод за комбиниране на техники за прогнозиране би довел до подобро представяне, както и че конструирания от него модел е ефективен при приложение за прогнозиране в реалния свят и би могъл да стимулира нов напредък в сферата на прогнозирането на база динамичните редове от данни.

18 Заедно с екипа си, през 1999 г., Тенсел [82] сравнява способностите на модели, базирани на линейна оптимизация, изкуствени невронни мрежи и генетични алгоритми да моделират динамични редове, като използват критериите за точност при моделирането, конвергенция и изчислително време. Те установяват, че методите на линейна оптимизация дават най-добри прогнози, въпреки че генетичните алгоритми може да осигурят същите стойности ако границите на параметрите и резолюцията са избрани правилно, но изкуствените невронни мрежи са дали най-лошите резултати. Те обаче отбелязват, че нелинейността може да бъде успешно манипулирана както от генетичните алгоритми, така и от невронните мрежи и че последните изискват минимална предварителна теоретична подготовка.

19 Гарлаускас [83], през 1999 разследва прогнозирането на цените на фондовия пазар на базата на динамични редове и изкуствената невронна мрежа, като използва изчислителен алгоритъм, свързан с подхода на функцията *karnel* и метода на рекурсивната прогнозна грешка. Основната идея за обучаването на изкуствената невронна мрежа чрез функцията *karnel* е, че функцията стимулира промените на теглата, за да се постигне сближаване на целевите и прогнозните изходни функции. Той прави заключението, че финансовите прогнози, базирани на динамични редове данни от невронните мрежи са по-добри от класическите статистически и други методи.

20 Чан и колектив [84] изследват възможностите за прогнозиране на цените на база динамични редове от финансови данни, използвайки изкуствена невронна мрежа с право разпространение на информацията и ежедневна информация за търговията на Шанхайската фондова борса през 2000 година. За да се подобри скоростта и сближаването, за обучението те използват алгоритъм за конюгиран градиент и множествена линейна регресия за нормализиране на теглата. Тяхното заключение е, че изкуствена невронна мрежа може да моделира времевите редове по задоволителен начин и че техният подход за обучение и инициализация на теглата води до по-добри резултати и по-ниски разходи на изчислителна мощност.

21 Ким и Хан [85] използват модифицирана с генетичен алгоритъм и изкуствена невронна мрежа, за да прогнозират цената на основния индекс на акции на Корейската фондова борса *Kospi Index*. В техния случай, генетичния алгоритъм се използва за намаляване на сложността на функционалното пространство чрез оптимизиране на праговете за дискретизация на елементите и оптимизиране на теглата на връзките между

слоеве. Целта им е била да се използва глобално претърсвана дискретизация на елементите, за да се намали измерението на пространството на функциите, да се премахнат нерелевантните фактори и да се смекчат ограниченията на алгоритъма за градиентно спускане. Данните за техния експеримент са съставени от дванадесет технически индикатора за период от единадесет години, като за обучение се използва 80% ,а за изпитване 20% от данните. Сред особеностите на тяхната невронна мрежа е фактът, че те фиксират броя на елементите в единственият скрит слой, за да отговаря на броя на входящите параметри на дванадесет. Те стигат до заключението, че подходът с генетичен алгоритъм и изкуствена невронна мрежа надминава конвенционалните модели за прогнозиране.

22 През 2000 година, Ромахи и Шен [86] отправят критики към изкуствените невронни мрежи и способността им да прогнозираят капиталовите пазари и разработват развиваща се експертна система, базирана на правила, за прогнозиране на капиталовите пазари. Техният подход е базиран на това да се слее размитата логика с базиран на правила подход, така че да се разработи система с възможности за обобщаване и висока разбираемост. По този начин променящата се пазарна динамика непрекъснато се отчита докато времето прогресира и базираната на правила система не остарява. Експериментът им е проведен на база ценова информация за индекса на най-големите борсово търгуеми американски компании Dow Jones Industrial Average. Те заключават, че тяхната методологията е обещаваща и се справя не по-лошо от изкуствените невронни мрежи, като основното ѝ предимство пред тях е свързано с нейната разбираемост.

23 Абрахам и колектив [87], разглеждат хибридизирани техники за автоматизирано прогнозиране на пазарите на акции и анализ на пазарни трендове. Те са използвали принципен анализ на компонентите за предварителна обработка на входните данни, изкуствена невронна мрежа за прогнозиране на цената на акциите за един ден напред и невро-размита система за анализ на тенденцията за прогнозните стойности на цените на акциите. За да демонстрират предложената техника, те анализират двадесет и четири месечни данни за цените на акциите на основния технологичен индекс в САЩ - Nasdaq 100, както и шест от компаниите, участващи в него. Те стигат до извода, че прогнозирането на цените на акциите и на трендовете в движението им при използване на предложената хибридна система са обещаващи и оправдават по-нататъшни изследвания и анализи.

24 През 2001, Циао и Тай [88] използват метода на поддържащите вектори за изучаване на дневните изменения на цените на щатския индекс на т.нар широк пазар - S&P 500, като сравняват неговото представяне с това на многослоен перцептрон, обучен с алгоритъм с обратно разпространение на грешката. Грешката на генерализацията по отношение на свободните параметри на метода на поддържащите вектори, изразена чрез няколко универсални измерителя е била обект на изследване и е установено, че оказва малко влияние върху решението. Те достигат до заключението, че е полезно да се прилага метода на поддържащите вектори за прогнозиране на финансови времеви редове.

25 Същата година и Х. Хауард [89] изследва възможността за прогнозиране с изкуствени невронни мрежи на времеви редове с структури, базирани на модел на авторегресивно - движеща се средна стойност. Използвайки симулацията и ефективността на модела Бокс-Кенкингс като еталон, той достига до заключението, че изкуствени невронни мрежи с право разпространение на информацията и обратно разпространение на грешката, се представят добре и последователно за времеви редове, съответстващи на структури от авторегресивно - движеща се средна стойност - ARMA (p, q). Той достига до заключението, че за повечето от структурите с изкуствени невронни мрежи с право разпространение на информацията и обратно разпространение

на грешката са се представили значително по-добре, когато определено ниво на шум бъде взето предвид по време на мрежово обучение. Затова, за по-добри резултати препоръчва, нивото на шум в данните използвани за обучение да бъде постоянно и с ниско стандартно отклонение.

26 През 2001 г. Куо и екип [90], като продължение на работата му от 1996 г., разработва базирана на генетичен алгоритъм размита невронна мрежа за формулиране на базата от знания на правилата за размити заключения, които могат да измерят качествения ефект (като политическия ефект) на фондовия пазар. Ефектът е допълнително интегриран с технически индекси чрез изкуствени невронни мрежи. Използвайки, базирани на Тайванския фондов пазар, за да оцени предложената интелигентна система, той стигна до извода, че базирана както на количествени (технически индекси), така и на качествени фактори невронна мрежа, е по-добра от тази, основана само на количествени фактори.

27 Люнг, Даук и Чен [91] провеждат проучване, което се фокусира върху оценката на нивото на възвръщаемост на индекс на фондовия пазар. Заявявайки, че прогнозиране с малка грешка не се превръща непременно в капиталова печалба те оценяват ефикасността на няколко техники за многовариантна класификация спрямо група подходи за оценка на нивата. Сред методите за прогнозиране на нивата са експоненциалното изглаждане, многопластова невронна мрежа с предаване напред на информацията и пробабилитична невронна мрежа. Използваните данни обхващат периода между 1967 и 1995 г. и включват дневните цени на щатския индекс S&P 500, великобританския FTSE 100 и японският индекс Nikkei 225, както и някои макроикономически показатели като индекс на потребителските цени и индекс на промишленото производство. Сравнението на прогнозиращата сила на моделите за класификация и оценка на нивата показва, че най-добри резултати при правилното прогнозиране на посоката на движение на индексите през 60 прогнозни периода извън шаблона от Януари 1991 г. до Декември 1995 г. продуцира многослойната невронна мрежа с предавана напред на информация и вероятностна невронна мрежа. За да се направи сравнение с класификатора на вероятностна невронна мрежа, те тестват ефективността на многослойния невронна мрежа с предавана напред информация. За разлика от пробабилитичната, която предлага групов класификация за даден набор от входове, многослойната мрежа предоставя точкова оценка или прогноза като изход. Въз основа на резултатите от тяхното проучване те избират архитектурата на мрежата, която води до последователно и прилично представяне при изпитването на модела (неговата валидация).

Авторите отбелязват и факта, че с въвеждането на електронни комуникационни мрежи, като електронни системи за търговия, улесняващи търговията с акции и други финансови продукти на водещите световни фондови борси, на първо място и по-късно на други не дотам известни фондови пазари и постоянно нарастващия интерес, както от страна на дребни, така и от страна на институционални инвеститори, инвестициите в акции, както и изследванията в тази област „избухват“. Напредъкът в изчислителната и комуникационната мощ позволява на изследователите да разработят модели, използващи изкуствени невронни мрежи, които се захранват с данни в реално време и способни да генерират сигнали за покупка и продажба в реално време.

28 В своя статия от 2000 Пан, Тилакаратне и Йърууд [92] представят изчислителен подход за прогнозиране на индекса на австралийския фондов пазар – AORD, като използват многослойна невронна мрежа с предавана напред информация с данни от времеви редове от австралийския фондов пазар и други фондови пазари. Тяхната цел е да се открие ефективна невронна мрежа или набор от адаптивни невронни мрежи за тази задача, която може да използва или моделира различни динамични движения и между-

пазарни влияния, открити чрез професионален технически анализ и количествен анализ. Представени са три аспекта на ефективност при избора от данни: ефективни входящи ресурси от самия целеви пазар (AORD), достатъчен набор от взаимосвързани пазари и ефективни входящи ресурси от взаимосвързаните пазари. Две традиционни измерения на архитектурата на невронната мрежа също са обект на разглеждане: оптималният брой скрити слоеве и оптималният брой скрити неврони за всеки скрит слой. Получени са три важни резултата: по време на проучвания период е бил открит 6-дневен цикъл на австралийския фондов пазар; времевия „отпечатък“ използван като допълнителен входящ индикатор, предоставя полезна информация; и базовата невронна мрежа, използваща шест дневна възвръщаемост на индекса AORD и една ежедневна възвръщаемост на S&P 500 плюс деня от седмицата, като входящи параметри показва до 80% правилно предсказване на посоката.

29 Е Каливас [93] се опитва да предскаже дневната свръх възвръщаемост на индексите FTSE 500 и S&P 500 над тримесечните съкровищни облигации, съответно над тази на Великобритания и САЩ. След това авторът прилага два различни вида модели за прогнозиране: авторегресионни и изкуствени невронни мрежи, за да прогнозира времевите серии с свръх възвръщаемостта, като използват стойности на индикаторите със забавяне. За да се избере оптималната топология на моделите с невронни мрежи се използва генетичен алгоритъм. Данните се състоят от 3 275 ежедневни наблюдения на индекса FTSE-100, доходността до падеж на Съкровищните облигации на Великобритания и 3 277 наблюдения на индекса S&P 500 и доходността до падеж на Съкровищните облигации на САЩ от 4 Януари 1988 г. до 12 Декември 2000 г. Авторът оценява прогнозните модели на база четири различни показателя и стига до заключението, че те не успяват да надвишават значително прогнозните способности на наивните модели за предсказване.

30 В тяхно ново изследване от 2003 г., Чен, Люнг и Доук [94] опитват да предрекат посоката на движение на пазарния индекс на Тайванската фондова борса, за времето си - един от най-бързо растящите капиталови пазари в развиваща се Азия. Те използват пробабилистична невронна мрежа за прогнозиране на посоката на възвръщаемостта на индекса, след като е обучена с исторически данни. Статистическите резултати от прогнозите на пробабилистична невронна мрежа се измерват и сравняват с тези на обобщените методи на моменти (ОММ) и с филтъра на Калман. Освен това прогнозите се прилагат към различни стратегии за търговия с индекси, чиито резултати се сравняват с тези генерирани от стратегията купи и задръж (buy-and-hold), както и няколко други вида пасивни стратегии за търговия. Те заключават, че емпиричните резултати показват, че инвестиционните стратегии основани на пробабилистична невронна мрежа, имат по-висока възвръщаемост от другите инвестиционни стратегии, разгледани в това проучване.

31 М. Версаче, Р Бхат, О. Хиндс и М. Шифер [95] оценяват представянето на хетерогенен микс от алгоритми за невронни мрежи за прогнозиране на борсово търгуван фонд, базиран върху индекса на сините чипове на американския пазар на акции - DJIA. Те използват генетичен алгоритъм, за да намерят най-добрата комбинация от невронни мрежи, топологията на отделните мрежи в ансамбъла и да определят набор от техни отличителни белези. Генетичен алгоритъм се използва за да определи размера на времения прозорец към който принадлежат входните данни, предоставен на отделни класификатори в набор от „експерти“. Комбинация от изкуствени невронни мрежи - експерти се състои от: повтарящи се мрежи с обратно разпространение грешката и мрежи с радиална базова функция. Списък на променливите използвани в това проучване се състои от данни от няколко под-индекса на Dow Jones и други известни индекси, валутни курсове и бенчмаркови емисии облигации за период от 11 ноември 2001 до 12 февруари

2003 г. или общо 320 търговски дни. Направеният от авторите извод е, че изкуствените невронни мрежи и генетичните алгоритми се представят сравнително добре и се очертават като добра техника за прогнозиране на стохастични динамични редове, като тези, наблюдавани в данните на фондовия пазар.

32 В техният доклад от 2004, Ким и Лий [96] сравняват метод за трансформация на елементите на мрежата с помощта на генетичен алгоритъм с два конвенционални метода за определяне топологията изкуствени невронни мрежи. Генетичен алгоритъм е включен, за да подобри възможностите за обучение и генерализация на изкуствените невронни мрежи в опита им за прогнозиране на фондовия пазар. Проведени са ежедневни прогнози и е измерена тяхната точност. Авторите използват предложения модел за прогнозиране на един от индексите на акции в Южна Корея - KOSPI. Сравнението на резултатите, постигнати чрез метод за преобразуване на характеристиките на мрежите, чрез генетичен алгоритъм и тези на други методи за трансформация на характеристиките, показва че предлаганият модел работи по-добре. Експерименталните резултати показват, че предложеният модел намалява обема на функционалното пространство и намалява неудачните фактори за прогнози на фондовите пазари

33 В статията си от 2006, К. Ким [97] предлага подход, който използва генетичен алгоритъм за подбор на примери за обучаването на изкуствени невронни мрежи, с цел извличане на финансови данни. Той отбелязва, че изкуствените невронни мрежи имат превъзходни умения за учене, но често показват последователно и непредсказуемо представяне при „шумни“ данни. В допълнение, може да не е възможно да се обучават изкуствени невронни мрежи или задачата за обучение не може ефективно да се осъществи без намаляване на обема на данните. Предложеният модел използва генетичен алгоритъм, за да оптимизира едновременно връзките между отделните слоеве и задачата за избор на данни. Глобално развитите тегла намаляват добре известните ограничения на алгоритъма градиентно спускане. Освен това, подобрените шаблони с помощта на генетичен алгоритъм, съкращават времето за обучение и подобряват ефективността на предсказването. Експерименталните резултати показват, че подходът с генетичния алгоритъм е обещаващ метод, за селекция на примери за обучаването на изкуствени невронни мрежи при модели за анализ на фондовия пазар.

34 Н. О'конър и М.Г. Мадън през 2005 [98] оценяват ефективността на използването на външни показатели, като цените на суровините и валутните курсове при прогнозиране на движенията в индекса Dow Jones Industrial Average. Ефективността на всяка техника се оценява, като се използват различни специфични за домейна показатели. Представена е всеобхватна процедура за оценка, включваща използването на симулации за търговия, за да се оцени практическата стойност на прогнозните модели и сравнението с традиционни бенчмарки за представянето на пазара. В представените резултати от експеримента, базираната на изкуствена невронна мрежа стратегия, обучена на базата на редица външни индикатори, довежда до възвръщаемост на инвестициите от 23.5% годишно за периода, когато индексът DJIA нараства с 13.03% годишно. Съставен е съществен набор от данни, който е на разположение на други изследователи заинтересовани от анализа на финансови времеви серии.

35 През 2007 Тилакаратне, Морис, Мамадов и Хърс [99] се опитват да изследват вътрешната взаимосвързаност и зависимости на капиталовите пазари. Проучването прогнозира сигнали за търговия на Австралийският широк индекс (AORD) за един ден напред. Тези прогнози се базират на относителната възвръщаемост за текущия ден на цената на затваряне на американския индекс S&P 500, индекса FTSE 100 във Великобритания, френския индекс CAC 40 и немския DAX, както и на AORD. Изследваните техники за прогнозиране са невронни мрежи с предавана напред информация и вероятностни невронни мрежи. Ефективността на мрежите е оценена чрез

използване на степен на класификация / грешна класификация и симулации на търговия. И при двата критерия за оценка, невронните мрежи с предавана напред информация се представят по-добре. Симулациите на търговия водят до заключението, че прогнозираните сигнали за търговия от техния модел са полезни за краткосрочните трейдъри.

36 Л. С. Масиел и Р. Балини [100] анализират възможността за приложение на изкуствените невронни мрежи за прогнозиране на времеви редове с финансова информация и по-конкретно няколко развити и един развиващ се пазар на акции. По-специално способността да се предвидят бъдещите тенденции на северноамериканските, европейските и бразилските фондови пазари. Точността се сравнява с традиционния статистически метод Autoregressive conditional heteroskedasticity (GARCH). Разгледани и избрани са най-подходящите, според тях топологии на невронните мрежи, за всеки от наборите с шаблонни данни. Тяхното изследване определя осъществимостта и практичността на използването на изкуствени невронни мрежи, като средство за прогнозиране от страна на индивидуалния инвеститор. Прави се заключението, че невронните мрежи имат мощен капацитет да прогнозира всички изследвани индекси на фондовия пазар и ако са обучени правилно, индивидуалният инвеститор би могъл да се възползва успешно от този прогнозен инструмент вместо да използва традиционните техники за прогнозиране.

37 Е. Хадаванди, А. Ганбари и Х. Шаванди [101] твърдят, че за успешно прогнозиране на фондовия пазар и постигането на най-добри резултати е необходимо да се използват минимално изискваните входни данни и най-малко сложния модел на фондовия пазар. За постигането на тези цел, тяхната статия от 2010 г. представя интегриран подход, базиран на генетични размити системи и изкуствени невронни мрежи за изграждане на експертна система за прогнозиране на цените на акциите. Първоначално те използват поетапен регресионен анализ, за да определят факторите, които оказват най-голямо влияние върху цените на акциите. На следващия етап те разделят необработените данни в „К“ клъстери посредством самоорганизиращи се карти от невронни мрежи и накрая всички клъстери се поставят в модели на независима генетична размита система със способност за извличане на сигнали за търговия, на база правила и настройка на бази данни. Оценка на възможностите на предложения подход е направена чрез прилагането му върху данните за цените на акциите от секторите на информационните технологии и авиокомпаниите и сравнена с резултати от предишни методи за прогнозиране на цените на акции като девиацията на модела се измерва с използване на средна абсолютна процентна грешка. Резултатите показват, че предложеният подход надхвърля всички предишни методи, така че може да се счита за подходящ инструмент за прогнозиране на цените на акциите.

38 През 2012 г. А. Гош [102] представя хибридна невронно-еволюционна методология за прогнозиране на времеви серии и прогнозиране на цената на технологичния индекс NASDAQ в частност. Методологията е хибридна, защото се използва процес на оптимизация, базиран на еволюционно изчисление, за да се създаде цялостен дизайн на невронна мрежа. Проектираната невронна мрежа, като модел, се използва за прогнозиране на времева серия. Процесът на идентифициране на модела включва манипулиране на данни от много опитен статистик, който извърши този процес. В сравнение с предишни работи този подход е чисто еволюционен, докато други използват смесени, предимно комбинирани с алгоритъма за обратно разпространение на грешката, за който е известно, че могат да попаднат в локални минимума. Чрез продуцираните от модела сигнали, еволюционният процес автоматизира идентифицирането на входните променливи, което позволява на потребителя да избягва предварителната обработка на данните и статистическия анализ. Проучването доказва

гъвкавостта на изкуствените невронни мрежи, като инструмент за прогнозиране на финансови времеви серии. Освен това, авторът прави заключението, че алгоритъма с конюгирано градиентно спускане (Conjugate Gradient Descent) се оказва ефективен при обратно разпространение на грешката и спокойно може да се използва за прогнозиране на средната цена на акциите на NASDAQ.

39 З. Чен и Х. Ду [103], в много иновативна статия от 2013 г. изучават връзките между социалните медии и финансовите пазари. Авторите използват популярен онлайн китайски форум за фондовия пазар на име Guba.com.cn, както и традиционните методи за анализ на настроеността на пазара. За всички борсово търгувани акции, обект на техния анализ изграждат графика на социалното поведение, базирана на онлайн поведението на човека, изчисляват основните характеристики на графиката и разкриват корелациите между обема / цената на търгуване и тези характеристики. Те използват невронна мрежа с обратно разпространение на грешката, за да предвидят обема на търговията и цената на акциите от фондовата борса Шанхай в Китай. Техният метод постига по-добър резултат в сравнение с традиционните модели базирани на обема на търговията / цената. Стратегията за търговия, базирана на този метод, постига печалба от 56.28% за период от три месеца, през който борсовият индекс се увеличи само с 1.17%.

40 А. Абеди и колектив [104] изучават способността на изкуствените невронни мрежи и авторегресивна интегрирана движеща се средна стойност (ARIMA) модел да прогнозира финансовите пазари на базата на данни от Нюйоркската фондова борса в опит да бъдат изяснени противоречивите, според тях мнения в литературата относно кой от двата метода е по-добър. Използваните входящи данни са съставени от ценова информация и данни за изтъргуван обем за период от 1988 година до 2011 г. за акциите на компанията Dell Inc. Заключението, което авторите правят е че изкуствената невронна мрежа с архитектура състояща се от 10 входящи, 17 елемента в скрития слой и 1 изход показва по-добри резултати от ARIMA по отношение на средната грешка.

41 А. Шета и колектив [105] използват машини с поддържащи вектори и изкуствени невронни мрежи за изграждането на модел за предсказване на нивото на индекса S&P 500, като сравняват представянето му с това на множествена линейна регресия. Базата данни, използвана в експеримента е съставена от 27 финансово-икономически променливи предимно от ценова информация за самия индекс и изтъргуван обем, но и то валутни курсове, цени на стоки и други световни фондови тържища. Общо 1 192 дни наблюдения от 2009 г. до 2014 г. на базата, на които са изготвени 143 шаблона, от които 100 бр. за обучение и 43 бр. за изпитване. Многослойният перцептрон, използван за прогнозиране притежава 27 входящи и само един изходящ неврон, прогнозиращ целта на изследване - стойността на индекса за предстоящата седмица. За броя на невроните в скрития слой се спират на цифрата 20, като най-успешна по отношение на средната квадратична и абсолютната средна грешка. На база на постигнатите резултати от трите изпитвани модела, те обобщават, че машините с поддържащи вектори се представят по-добре от другите, като сред носещите им преимущество силни страни са набора от различни функции, които им позволяват да разрешават множество класификационни проблеми и по-голямата вероятност SVM да избягват проблема с попадане в локални минимума при обучението.

42 М Киу и Ю Сонг [106] сравняват два основни вида входящи променливи за предричане на посоката на движение на индекса на Японския фондов пазар Nikkei 225. За да подобрят акуратността на използваната от тях оптимизирана изкуствен невронна мрежа си служат с генетични алгоритми. Използваните данни са за период от шест години и 1 707 търговски сесии. Те разделят входящите параметри на 2 групи, нормализират стойностите им, за да намалят експоненциалните грешки, оптимизират теглата в мрежата с помощта на генетичен алгоритъм и сравняват със данни не

принадлежащи на шаблоните за обучение - 300 на брой. Авторите стигат до заключението, че входящите параметри имат значително влияние върху резултатите, постигнати от модела и въпреки по-добрите резултати на едните и фактът, че представянето на модела им превъзхожда това на други подобни, могат да се търсят подобрения за него в три направления: по отношение на входните данни - да бъде направена по-прецизна селекция, по отношение на алгоритъма за обучение - да се потърси по-оптимален подход, различен от генетичния алгоритъм и трето - да се разработи инвестиционна стратегия на база резултатите от модела за прогнозиране.

43 Д. Нелсън и колектив [107] се заемат със задачата да прогнозират пазара на акции, които те определят като невероятно сложен, динамичен и хаотичен. В експеримента си те използват разновидност на повтарящи се изкуствени невронни мрежи - мрежи с къса и дълга памет (long-short term memory networks) за да предвидят бъдещи трендове на базата на ценова информация и технически индикатори. Данните са за период от 2008 г. до 2015 г. и са на базата на т.хар Японски свещи за 15 - минутен период, което не е сред най-традиционно използваните на пазара. Обект на проучване е Бразилският пазарен индекс iBovespa и няколко индивидуални акции. Резултатите са сравнени с тези на някои други техники на машинното обучение, сред които и многослоен перцептрон. Постигнатите резултати се определят като обещаващи, като най-успешния модел продуцира точни прогнози в 56% от случаите.

44 Е. Чонг и колектив [108] използват дълбоко обучение на невронни мрежи за прогноза на корейския индекс Kospі на база на 38-те най-ликвидни негови компонента. Авторите акцентират върху важността за трансформиране на данните преди представянето им на входа на системата, като предлагат три неконтролирани метода за представяне на данни: анализ на основните компоненти (PCA) с линейна трансформация, автокодер (AE) и ограничена машина на Boltzmann (RBM). Данните са за 5 годишен период, между 2010 г. и 2014 г., като от тях 80% са използвани за обучение, а останалите 20% са разделени между тестови и валидиращ сет. Представянето на модела се измерва чрез стандартната нормализирана средна квадратна и средната абсолютна грешка. Резултатите от експеримента показват по-добро представяне на невронната мрежа в сравнение с авторегресионните модели за прогнозиране при данните за обучение и почти еднакво представяне на тестовите данни. Интересен факт е, че предложените техники за подготовка на данните не дават резултат и моделите се представят по-добре, работейки с необработени данни.

45 М. Резе и екипът му [109] разработват експертна система в която интегрират размити C-means клъстери и Data envelopement Analysis заедно с невронни мрежи за прогнозиране на цените на компании, листнати на фондовата борса в Техеран. Те използват данни от финансовите отчети и производни на тях, по-често асоциирани с фундаменталния анализ, за компаниите на този екзотичен пазар за периода 2007 - 2012 година. Данните са разделени на два сета, като 70% са предназначени за обучението на използвания в модела многослоен перцептрон, а останалата част са отредени за изпитващи. Оценката за представянето на модела се извършва на база средната квадратична грешка. Резултатите, според авторите са добри и улесняват взимането на решения за търговия.

46 Н. Табари и екипът му [110] правят много интересно изследване на настроеността на финансовите пазари, на базата на съобщения в социалната мрежа Twitter и зависимостите им спрямо измененията на пазара на акции през 2018 г. Данните за експеримента са от периода 01.01.2017 - 31.03.2017 година, като след налагането на някои филтриращи техники, за да се уверят че съобщенията са релевантни са получени 20 хил. туита. Тези данни се групират в 4 под групи, определящи, разделящи ги най-общо, като позитивни и негативни. За да не се задава небалансиран наклон на данните,

те се преподреждат в подгрупи. Няколко архитектури на изкуствена невронна мрежа са изпитани, като авторите се спират на мрежа с къса и дълга памет (long-short term memory networks). Резултатите се определят като успешни, като дори авторите провеждат и втори експеримент само на базата на най-споменаваните акции в туитове, които са Епъл, Амазон, и Фейсбук, за по дълъг период от над 3 години и над 380 хил туита. За същия период се анализира измененията на цените на акциите и се сравнява настроеността на пазара за различни времеви интервали, вариращи от петнадесет минути до един ден. Според авторите, се наблюдават два двойствена взаимовръзка, от една страна оценката на настроеността влияе на цените на акциите и цените на акциите влияят на настроеността.

47 С. Чопра и екипът му [111] изпробват способността на изкуствените невронни мрежи за прогнозиране на цените на девет акции и индекса Nifty 50 преди и след демонетизацията в Индия. Деветте акции са разделени по отношение на волатилността и капитализацията си. Данни за обучение, тестване и валидиране за всяка акция се състои от поне осем години, като са разпределени в различни сетове с данни, всеки от които е разделен в пропорция 75%, 15% и 15%, съответно за обучаване, изпитване и валидиране на мрежата. Многопластовите невронни мрежи се обучават по алгоритъма на Левенберг-Маркард (Levenberg-Marquardt). Функцията за прехвърляне на скритите слоеве е допирателна сигмоида, а функцията за прехвърляне на изходния слой е линейна. Няколко мрежи се предлагат, като варират в броя на невроните, за да се постигне минимална средна квадратна грешка. Стойностите, продуцирани по време на обучението са 0.999 за всички мрежи, което показва висока ефективност на проектирана невронна мрежа. Прогнозираните стойности от обучените мрежи се валидират с действителни стойности преди и след демонетизацията в Индия от Ноември 2016 година.

48 Ю. Хуанг и колеги [112] (2019), представят статия, в която сравняват представянето на модел с изкуствена невронна мрежа и такъв с размита логика за прогнозиране на цените на акции от индекса S&P 100 на щатския фондов пазар. Данните за експеримента са изцяло от сферата на фундаменталния анализ и се състоят от информацията от финансовите отчети на компаниите към края на всяко тримесечие от 1996 г. до 2017 г. Авторите си поставят за задача да изградят отделни портфейли (съдържащи акции за покупка и такива за продажба) и да сравнят представянето им спрямо индекса. След предварителна обработка на данните са избрани 21 финансови показателя, а разпределението между данни за обучение, изпитване и валидация е съответно 60%, 20% и 20%. В заключението им се отбелязва, че и двата метода успешно отделят печелившите от губещите позиции и че изградените портфейли успяват да се представят по-добре от бенчмарка си.

Сред всички изследвания извършени през годините, български автори също проявяват активност, като изпитват модели, използващи изкуствени невронни мрежи за да предскажат поведението на фондовия пазар.

49 През 2008 г. доц. д-р Тодорка Атанасова, хон.ас. Валерия Симеонова от катедра “Информатика” в Икономически университет- Варна пишат труда си „Възможности За Прогнозиране На Борсови Индекси С Неврони Мрежи и Генетични Алгоритми“ [113], в което целта е да се покаже, че е възможно прогнозирането на краткосрочното движение на капиталовите пазари, в частност на индексите на Българска Фондова Борса – BG40 (индекс на капитализация на най-търгуваните дружества за последните 6 месеца) и Sofix (индекс на капитализация на най-ликвидните дружества) със средствата и методите на невронните мрежи и генетичните алгоритми. Експериментално е установено, че най-добри резултати при работа с изградените от тях модел се получават при мрежи, чиято архитектура включва максимум 2 скрити слоя. Възможно е в хромозомата да се включат и настройващите параметри за обучаващите мрежата алгоритми.

Работата на модела продуциран от авторите, бива съпроводена с тестове, които доказват, че използването на невронни мрежи в комбинация с генетични алгоритми не затормозява процесора на компютъра. Следователно той е приложим към всеки стандартен компютър с инсталации на MS Excel. моделът е изпълним и в среда на Интернет.

Проучвания на авторите показват, че в България засега не се използват подобни модели. Една от причините за това е ограничения брой специалисти в областта на Изкуствения интелект и недостатъчното познаване на мощните технологии в тази сфера. Също така се прави заключение, че присъединяването на България към Европейския съюз и неговите финансови пазари може да бъде движеща сила в разработването на сектора на софтуерни продукти за прогнозиране на финансовите пазари, чрез методи на изкуствения интелект.

50 Тодор Димитров Балабанов [114] изготвя доклад, в който е представен модел за прогнозиране на времеви редове, базиран на изкуствени невронни мрежи. За цел на изследването си той поставя намирането на алгоритми за по-бързо и по-ефективно обучение на ИНМ, които да решават задачите за прогнозиране на времеви редове. На по-късен етап в дисертационния си труд той, експериментира с модел базиран на изкуствени невронни мрежи, чието обучение се извършва с диференциална еволюция, под формата на изчисления в разпределена среда. Направен е опит за прогнозиране на валутния пазар на база на времеви редове, като двата най-актуални модела мрежи, според автора са класическа трислойна мрежа, без обратни връзки и мрежа с обратни връзки. И двете мрежи са обучени, при равни други условия. Заключение е, че напълно-свързаната мрежа показва по-добри параметри, за по-малко епохи обучение.

51 Интересен материал по темата е публикуван от един български инвестиционен посредник – Карол, наречен „Търгуване чрез невронни мрежи“ [115], в който авторът Станислав Иванов представя изкуствените невронни мрежи, като модел за дълбоко обучение ползван за финансов анализ, способен да разпознава шаблони по-добре от човек. Макар и спорен, материалът, все пак е колкото информативен толкова и насочен към привличането на вниманието на читателите с цел подтикване към търговия. Липсата на конкретни резултати не позволява да се коментира успешна или не е предлаганата стратегия за търговия.

В процеса на разглеждане на научните трудове във времето, авторът на дисертационния труд се натъква на няколко изчерпателни обобщаващи работата в тази научна област материали, които ще бъдат разгледани в следващите редове.

52 През 2017 година, О. Икан и Т. Челик [116] от университета в Самсун, правят опит да изследват модели, базирани на изкуствени невронни мрежи за точността на резултатите от техни прогностични задачи на базата на финансови времеви редове с информация. Те сравняват и успеваемостта и рентабилността на моделите спрямо определените от авторите на съответните трудове бенчмарки, но цитирайки че някои от основните измерители на тези данни от рода на средна абсолютна девиация, средна квадратична грешка и средна абсолютна грешка, заявяват, че ще използват точността на прогнозите по отношение на посоката или отношението точни/неточни прогнози. Те успяват да пресяват разгледаните статии до 25 броя, и ги съпоставят в таблична форма за прегледност. В заключението си те изказват мнение, че прегледаните статии най-често предлагат изкуствени невронни мрежи в съчетание с друга техника от сферата на статистическата или машинно обучение, като дават по-добри резултати. Освен това, анализ с помощта на многовариантни статистически техники на бази данни, които ще бъдат подадени за обучение на невронни мрежи, предвещава по-успешен набор от хибридни модели. Така, насърчаването на хибридни модели не би било неразумно в случаи на прогнозиране финансови времеви серии.

53 М. Ткач и Р Вернер [117] от Икономическия университет в Братислава през 2015 г. правят преглед на разработките и приложението на изкуствени невронни мрежи в бизнеса като цяло през последните две десетилетия. Те установяват, че въпреки нарастващия брой изследователски трудове, само няколко проучвания са представени, фокусирани върху прегледа на публикуваните открития в тази важна и популярна област, а голяма част от тях датират от преди повече от 15 години. Целта на техният труд е да разшири обхвата на по-ранните проучвания и да предостави систематичен преглед на приложенията на невронните мрежи в бизнеса между 1994 г. и 2015 г., обхващайки и класифицирайки по основни характеристики 412 научни статии. Тя откриват че немалка част от разгледаните, се занимават с проблема за прогнозиране на финансови пазари, наред с други по-традиционни, като класификационни задачи и платежоспособност на лица и фирми. Като най-конвенционални са отбелязани мрежите с разпространение на информацията напред и обратно разпространение на грешката чрез алгоритъма за градиентно спускане. Те виждат голям потенциал за нови изследвания в областта.

Във свое собствено изследване в тази насока, авторът на дисертационния труд и колектив изготвят обзорна статия по темата, в която правят някои собствени заключения. Едно от тях е, че „Въпреки че невронните мрежи не са перфектни в техните прогнози, те, изглежда че се представят по-добре от други методи и дават надежда, че с тяхна помощ някой ден ще можем да разберем напълно динамичните, хаотични системи на финансовите пазари.“ [118], [119]

Авторът смята, че на база на детайлното разглеждане на голям брой статии и основната цел на дисертационния труд, а именно изследване на модели за прогнозиране на капиталовите пазари с изкуствени невронни мрежи и краткото представяне на избрани 53 на брой труда, подредени в хронологичен ред, е постигната едно добро покритие на тази, радваща се на все по-силен интерес научна област. С цел онагледяване на проучването и формиране на заключение относно способностите на изкуствените невронни мрежи за успешно прогнозиране на капиталовите пазари е представена таблица с резултатите от всички прегледани статии заедно с някои детайли за тях. В Таблица 5 по долу са показани както следва: авторите, предметът на прогнозиране, използваните входящи данни, достигнатото заключение, след което са направени някои обобщения и изводи на база на получената информация, които е добре да бъдат отчетени с цел правилното формулирани и провеждане на експерименти в областта.

№	Автор/и	Предмет на прогнозиране	Използвани данни	Заключение
1	Х. Уайт	Дневната възвръщаемост на обикновенните акции на IBM	Дневна възвръщаемост на акциите на IBM от 1972 до 1978	"Представената невронна мрежа не е машина за пари"
2	Т. Кимото и колектив	Сигнали за покупка и продажба за индекса TOPIX	Векторна крива, обем на търговия, лихвен процент, валутен курс и стойността на DJIA	„Този метод не може да бъде използван за действителна търговия с акции.“
3	К. Камичо и Т. Танигава	Бъдещата цена на акции листнати на Токийската борса	Дневен минимум и максимум, както и цена на затваряне	„Подобно познание може да бъде полезно в преценката дали ръста в цената е перманентен“
4	И. Матсуба	възвръщаемост на пазара на акции	N-n прогноза за стъпка напред с последните n стойности на индекс, ползвани за входящ параметър	„Продуцираните резултати са добри“

5	Б. Фрейслибен	Стойността на индекс на немския пазар - FAZ Index	5 и 10 седмичната плъзгаща се средна и динамична симулация по време на обучение	„Мрежата, захранвана с технически индикатори се представя по-добре от обучената само с минали стойности на индекса“
6	К. Камичо и Т. Танигава	Цените на акциите на Токийската борса	Дневни данни за 33 месеца	„Моделът се представя по-добре от стратегия купи и държи и от индекса“
7	П. Уилсън	Цени на акции в САЩ	Комбинация от технически, адаптивни (базирани на ограничените функции за поддръжка - limited support functions) и статистически индикатори	„Тази архитектура притежава потенциал“
8	Е. М. Азоф	Неговата книга предоставя знанията, които се изискват за правилното проектиране и използване на изкуствена невронна мрежа в прогнозирането на финансовите пазари - с акцент върху търговията с фючърси.		
9	Р. Дж. Ван Ейдън	Моделирала работата на фондовата борса в Йоханесбург	63 различни индикатора	„Системата JSE демонстрира превъзходно представяне“
10	И. Кастра и М. Бойд	Цени на акции на фючърси върху стоки	Икономически данни под формата на времеви редове	ИНМ са способни да прогнозира до девет месеца напред във времето и се справят по-добре от наивен модел
11	Ч. Чанг и колектив	Нетна стойност на активите за края на годината на взаимни фондове	Историческа икономическа информация	„Системата се представя съществено по-добре от регресионните методи“
12	Р. Куо и колектив	Пазара на акции в Тайван	Качествени и количествени фактори	Играят много важна роля
13	С. Ким и Чун	Бъдещото движение на индекс на фондов пазар	Таблица с грешки, която служи като база за сравнение	„Прецедентно базираните разсъждения, са склонни да се представят по-добре от всички изброени изкуствени невронни мрежи“
14	Айкен и Бсад	доходността до падеж по тримесечните съкровищни бонове на САЩ	Доходност по правителствени облигации и макро данни	„Изкуствени невронни мрежи могат да се използват за правилно предвиждане на лихвите“
15	Д. Еделман и колектив	Идентифициране на възможностите за арбитраж в Австралийския официален индекс	Стойности на индекса и коефициент на Шарп	„Прогнозите на изкуствените невронни мрежа надминаха стратегията за купуване и държане, както и "наивните прогнози"“
16	А. Тамаmano	Бъдещата стойност на акциите на най-голямата Тайландска банка	Цена на затваряне за последните 3 месеца и ROA, ROE и P/E	„Невро-размита архитектура е в състояние да прогнозира по-бързо и по-точно от основния алгоритъм за обратно разпространение на грешката“
17	Т. Трафалис	Промяната в индекса S&P 500 за предстоящата седмица	Промените в 14 индикатора	„По-софистициран метод за комбиниране на техники за прогнозиране би довел до подобро представяне“

18	И. Тенсел и колектив	Способността на изкуствени невронни мрежи да моделират динамични редове	Конвергенция и изчислително време	Изкуствените невронни мрежи дават най-лошите резултати
19	А. Гарлаускас	Прогнозиране на динамични редове от цени на акции	Данни за цените на акциите	Невронните мрежи са по-добри от класическите статистически и други методи
20	М. Чан и колектив	Цените на акциите на Shanghai Stock Exchange	Дневни данни за търговията на Shanghai Stock Exchange	Невронните мрежи могат успешно да моделират динамични редове
21	К. Ким и И. Хан	Прогноза за цената на индекс на акции Kосpi	Данни за цените на акциите	Подходът надминава конвенционалните модели
22	Я. Романи и К. Шен	Експертна система, базирана на правила, за прогнозиране на финансовите пазари	Данни за цените на акциите	Тяхната методологията е обещаваща
23	А. Абрахам и колектив	Автоматизирано прогнозиране на пазарите на акции и анализ на пазарни трендове	24-месечни данни за цените на акциите на Nasdaq 100 и шест от компаниите в него	Резултатите са обещаващи и оправдават по-нататъшни изследвания и анализи
24	Л. Цяо и Ф. Тай	Изучаване на дневните изменения на цените на S&P 500	Дневни изменения на цените на S&P 500	Полезно е да се прилага метода на поддържащите вектори за прогнозиране на финансови времеви редове
25	Х. Хауарнг	Прогнозиране с изкуствени невронни мрежи на времеви редове с структури, базирани на модел на авторегресивно - движеща се средна стойност	Данни за цените на акциите	Изкуствени невронни мрежи се представят добре и последователно
26	Р. Куо	Прогнозиране на Тайванския пазар на акции	Качествени и количествени фактори на пазара на акции	Моделът се представя по-добре от други
27	М. Люг, Х. Даук и А. Чен	Нивото на възвръщаемост на индекс на фондовия пазар	дневните цени на S&P 500, FTSE 100 и Nikkei 225, индекс на потребителските цени и индекс на промишленото производство между 1967 и 1995 г.	най-добра ефективност при правилно предвиждане на посоката е тази на многослойната невронната мрежа за подавана напред напред
28	Х. Пан, И. Тилакаратне и Д. Иърууд	Сигнали за търговия на Австралийският широк индекс (AORD)	Ценова информация за S&P 500, DJIA Nasdaq 100, фючърси върху злато, сребро и петрол	Базова невронна мрежа показва 80 % успеваемост в прогнозиране посоката на пазара
29	Е. Каливас	Дневната свръх възвръщаемост на индексите FTSE 500 и S&P 500 над съответните тримесечни съкровищни облигации	3 275 дневни наблюдения на индекса FTSE-100, доходността до падеж на Съкровищните облигации на Великобритания и САЩ и 3 277 наблюдения на индекса S&P 500 от 4 Януари 1988 г. до 12 Декември 2000 г.	ИНМ не успяват да надвишат значително способността за прогнозиране на наивните предсказатели“
30	М. Люг, Х. Даук и А. Чен	Посоката на движение на пазарния индекс на Тайванската фондова борса	Данни за цените на акциите	Вероятностна невронна мрежа има по-висока възвръщаемост от другите инвестиционни стратегии

31	М. Версаче, Р Бхат, О. Хиндс и М. Шифер	Прогнозиране на борсово търгуван фонд, базиран върху индекса DJIA	Данни за няколко подиндекса на Dow Jones и други известни индекси, валутни курсове и бенчмаркови облигации за период от 11 ноември 2001 до 12 февруари 2003 г.	Изкуствените невронни мрежи и генетични алгоритми се представят сравнително добре и се очертават като добра техника за прогнозиране
32	К. Ким и У. Лий	Цените на индекса от акциите в Южна Корея - Kospі	Данни за цените на акциите	Намалява неудачните фактори за прогнози на фондовите пазари
33	К. Ким	Генетичен алгоритъм за подбор на примери за обучаването на изкуствени невронни мрежи за прогнозиране на Kospі	Ценова информация за 8 години включваща 2 348 търговски сесии	Подходът с генетичния алгоритъм е обещаващ за селекция на примери за обучаването на изкуствени невронни мрежи
34	Н. О'конър и М.Г. Мадън	Прогнозиране на движенията в индекса Dow Jones Industrial Average	Ценова информация за индекса, цени на търгувани суровини и валутните курсове	Моделът продуцира възвръщаемост на инвестициите от 23.5% годишно за периода, когато индексът DJIA нараства с 13.03% годишно
35	Тилакаратне, Морис, Мамадов и Хърс	Сигнали за търговия на Австралийският широк индекс (AORD)	Ценова информация за индексите: S&P 500, FTSE 100, CAC 40 и DAX	Прогнозираните сигнали за търговия са полезни за краткосрочните трейдъри
36	Л. С. Масиел и Р. Балини	Бъдещите тенденции на северноамериканските, европейските и бразилските фондови пазари	Данни за цените на акциите	Невронните мрежи имат мощен капацитет да прогнозират всички изследвани индекси
37	Е. Хадаванди, А. Ганбари и Х. Шаванди	Прогнозиране на фондовия пазар	Цените на акциите в секторите на информационните технологии и авиокомпаниите	Предложеният подход надхвърля всички предишни методи, така че може да се счита за подходящ инструмент за прогнозиране на цените на акциите
38	А. Гош	Прогнозиране на цената на технологичния индекс NASDAQ	Данни за цените на акциите	Алгоритъма Конюгирано градиентно спускане е ефективен за обратно разпространение, може да бъде приет за прогнозиране на средната цена на акциите на NASDAQ
39	З. Чен и Х. Ду	Връзките между социалните медии и капиталовите пазари и цената на акциите от фондовата борса Шанхай	Китайски форум за фондовия пазар на име Guba.com.cn и традиционни показатели за настроението на пазара	Методът постига по-добър резултат в сравнение с традиционните модели
40	А. Абеди, А. Адеуими и Ч. Айо	Съпоставка на изкуствени невронни мрежи и авторегресивна интегрирана движеща се средна стойност (ARIMA)	Ценова информация, изтъргуван обем за период 1988 - 2011 г. за акциите на компанията Dell Inc	Изкуствената невронна мрежа показва по-добри резултати от ARIMA по отношение на средната грешка


41	А. Шета, С. Елсир и М. Фарис	Предсказване на нивото на индекса S&P 500, като сравняват представянето му с това на множествена линейна регресия	27 финансово-икономически променливи, ценова информация, изтъргуван обем, валутни курсове, цени на стоки и други световни фондови индекси	Машините с поддържащи вектори се представят по-добре от другите
42	М. Куи и Ю. Сонг	Посоката на движение на индекса на Японския фондов пазар Nikkei 225	Данни за 2 групи технически индикатори за 1 707 търговски сесии	Представянето на модела им превъзхожда това на други подобни
43	Д. Нелсон и А. Перейра	Бразилският пазарен индекс iBovespa и няколко индивидуални акции	Данни за период 2008 - 2015 г. ценова информация на база на Японски свещи за 15 минутен период	Най-успешния модел продуцира точни прогнози в 56% от случаите, резултати се определят като обещаващи
44	Е. Чонг, Ч. Хан и Ф. Парк	Прогноза на корейския индекс Kospі на база селектирани 38-те най-ликвидни негови компании	Пет минутна логаритмична възвръщаемост на акциите за период от Януари 2010 - Декември 2014	По-добро представяне на невронната мрежа в сравнение с авторегресионните модели за прогнозиране
45	М. Резе, М. Йозмалеки и М. Валипор	Прогнозиране на цените на компании, листнати на фондовата борса в Техеран на база показатели от финансови отчети	Данни от финансови отчети за период 2007 - 2012 година.	Резултатите, според авторите са добри и улесняват взимането на решения за търговия
46	Н. Табари, А. Сейдитаба ри, Т. Педи и В. Задрожни	Изследване на настроеността на финансовите пазари, на базата на съобщения в социалната мрежа Twitter	След филтриране - 20 хил туита за периода 01.01.2017 - 31.03.2017 и 380 хил туита за друг тригодишен период	Наблюдава се двойствена взаимовръзка, от една страна оценката на настроеността влияе на цените на акциите и цените на акциите влияят на настроеността
47	С Чопра, Д. Ядев и А. Чопра	Прогнозиране на цените на девет акции и индекса Nifty 50 преди и след демонетизацията в Индия.	Дневна ценова информация за акциите и индекса Nifty 50 за периода 2002 - 2016	Прогнозираните стойности от обучените мрежи се валидират с действителни стойности преди и след демонетизацията в Индия
48	Я. Хуанг, Л. Чепрез и Д. Хо	Прогнозиране на цените на акции от индекса S&P 100 на щатския фондов пазар	Информация от финансовите отчети за всяко тримесечие от 1996 г. до 2017 г. - 88 бр	Моделите успешно отделят печелившите от губещите позиции и че изградените портфейли успяват да се представят по-добре от бенчмарка си
49	Тодорка Атанасова, хон.ас. Валерия Симеонов а	Прогнозирането на краткосрочното движение на BG40 и Sofix	Данни за цените на индексите	Изследването показва добри резултати
50	Тодор Балабанов	Сравнение между различни топологии на ИНМ. Прогнозиране на валутния пазар.	Условие за край на обучението: изтичане на 24 часа	Напълно-свързаната мрежа показва по-добри параметри, за по-малко епохи обучение
51	Станислав Иванов/ Карол Брокер	Въведение в темата и представяне (и с рекламна цел) на възможностите на ИНМ като подпомагащо средство за търговия на финансовите пазари	Не е цитиран експеримент или доказателствен материал.	ИНМ могат да подпомогнат прогнозирането на финансовите пазари

52	О. Икан и Т. Челик	Цялостна оценка на способностите на ИНМ за прогнозиране на база времеви редове с финансова информация	Разглеждат множество статии от които пресяват 25 на брой	ИНМ в съчетание с друга техника от сферата на статистическата или машинно обучение, като дават по-добри резултати от моделите ползвани за сравнение
53	М. Ткач и Р Вернер	Цялостна оценка на способностите на ИНМ за прогнозиране на база времеви редове с финансова информация	412 научни статии за периода от 1994 до 2015	Виждат добра успеваемост на моделите и виждат голям потенциал за нови изследвания в областта.

Таблица 5: Обобщено представяне на разгледаните трудове

2.7.2 Анализ на резултатите от разгледаните трудове


Прави впечатление, че измежду детайлно разгледаните релевантни към темата трудове преобладава заключението, че моделите използващи невронни мрежи за прогнозиране на капиталовите пазари постигат по-добри резултати от традиционните техники или други методи на изкуственият интелект и машинното обучение. Видимо от графиката отдолу, че в 20.75% (единадесет от научните статии) авторите намират представянето на изкуствените невронни мрежи за незадоволително или по-малко успешно от методите с които те са били сравнявани, докато в останалите изследвания (79.25%) заключението е положително. Този резултат на пръв поглед изглежда доста убедително, но в никакъв случай не означава, че невронните мрежи, използвани сами или в комбинация с други техники на изкуствения интелект са машина за пари. Фигура 7 показва схематично това наблюдение.



Фигура 7: Резултат от разгледаните статии според техните автори


Според автора, те могат да бъдат ползвани, като като основен двигател на модел за предсказване, така и като допълващо или съпътстващо изследване, и в комбинация с традиционните методи за прогнозиране и по този начин подпомагат прилагането на успешни стратегии за търговия.

Сред използваните архитектури, определено се откроява тази на изкуствени невронни мрежи с разпространение на информацията направо / Многослоен перцептрон (MPL), използвани 37 пъти. Сред по-малко популярните разновидности са изкуствени невронни мрежи с радиална базова функция (RBFNN), използвана 3 пъти, вероятностни изкуствени невронни мрежи (PNN), ползвана 4 пъти и изкуствени невронни мрежи с обща регресия (GRNN) – само веднъж. В категория други архитектури, където цифрата е 19, трябва да се отбележи, че са налице някои по-нови, или поне добили повече популярност в по-скорошните изследвания като например мрежи с къса и дълга памет и дълбоко обучаваща се невронна мрежа, наред със считаните за по-традиционни рекурентни невронни мрежи (RANN). Фигура 8 показва разпределението по видове невронни мрежи в разгледаните изследвания.



Фигура 8: Разпределение на използваните архитектури на ИНМ

Пазарите, обект на изследване, са друг критерий, по който се наблюдава струпване около дефинираните като развити пазари – 32 пъти обект на интерес, следвани от т. нар. развиващи се пазари с 14 прогнозираня. Не случайно идеята на автора е да се насочи, именно към тази ниша на неизследвани и слабо познати пазари като българския, представен от едно изследване. Нужно е да се споменат и наистина екзотичните дестинации на които това изследване „заведе“ автора, класифицирано като Други, а именно фондовия пазар в Техеран, Иран и този на Тайланд. Фигура 9 показва разпределението по видове пазари на научните статии.



Фигура 9: Класификация на пазара обект на изследване

Задоволителните резултати от прилагането на методите от областта на изкуственият интелект, предизвикват нарастващо внимание от страна, както в научните среди, така и сред професионално заетите в сектора на инвестициите във финансови инструменти. Предизвикателството да се печелят пари от инвестиции в финансови инструменти все пак изисква усъвършенствани методи и правилен подбор на различните компоненти от моделите, като входните данни, архитектурата на мрежата, методите за обучение и в крайна сметка начина на материализиране на продуцираните резултати.

В разгледаните научни статии се забелязва тенденцията, обект на изследване да бъдат големите световни пазари в развити държави и акциите и индексите съставени от акции на мултинационални компании, търгувани в някои случаи на няколко различни пазари, като и широки и по-тесни (отраслови) индекси. Тези компании и индекси генерират огромни по размер оборот и внимание от страна не само на инвестиционната общност, но и от широката публика в глобален мащаб, като тяхното представяне служи за своеобразен барометър на състоянието на глобалната икономика, и икономиката на отделни региони, отрасли и държави. Ако вземем за пример Индексът S&P 500 или Dow Jones Industrial Average, макар и различни по своята специфика (S&P 500 е претеглен индекс на база пазарна капитализация на 500-те големи компании, докато Dow Jones Industrial Average е ценово претеглен на 30 най-значителни компании на NYSE), те представляват определящи тренда индикатори за целият глобален пазар на акции. Причините за това са множество и комплексни, но сред водещите могат да се назоват, размерът и влиянието на икономиката на САЩ върху световната икономика, фактът че повечето компании оперират във всички краища на развития свят и много др. В това отношение интересът към тях на повече изследователи е оправдан, но по-малките и неликвидни пазари в т. нар. възникващи пазари също заслужават внимание. Макар при тях липсата на голям паричен оборот да се отразява и зависимостта от събитията на световната икономическа сцена да е много по-слабо изразена, е налице рядко експлоатираната възможност да се изпита способността на изкуствените невронни мрежи да прогнозираят и такива пазари. Любопитно е да се разбере дали след подходящ избор на: модел за прогнозиране, архитектура на модела, алгоритъм за обучение, активизираща функция и не на последно място входящи параметри за модела, ще може да

се търси паралел в представянето на изкуствените невронни мрежи в прогнозирането на ликвидни световни пазари и неликвидни локални такива.

ГЛАВА III: РЕЗУЛТАТИ ОТ ИЗСЛЕДВАНЕТО НА МОДЕЛИ ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИ ПАЗАРИ С НЕВРОННИ МРЕЖИ И РАЗРАБОТВАНЕ НА ХИБРИДЕН МОДЕЛ ОТ НЕВРОННИ МРЕЖИ И СИСТЕМИ ОСНОВАНИ НА ПРАВИЛА ЗА ПРОГНОЗИРАНЕ НА КАПИТАЛОВИЯ ПАЗАР

3. Български фондов пазар

Първата българска фондова борса е създадена в София през 1914 г., като през 1933 г. на нея се търгуват 30 компании, като постепенно се увеличават нейните обороти [138]. През 1947 г. тя преустановява дейността си.

Българският капиталов пазар е възстановен след като през 1991 г. Народното събрание приема Търговския закон и създава условия за учредяване и функциониране на търговски дружества. През същата година се създава и първата българска борса.

През 1995 г. се приема първият регулаторен акт, уреждащ отношенията на капиталовия пазар – Закон за ценните книжа, фондовите борси и инвестиционните дружества (ЗЦКФБИД), като се създава и специален надзорен орган на пазара на ценни книжа – Комисията за ценните книжа и фондовите борси (КЦКФБ).

В периода 1995 – 1996 г. се изгражда инфраструктурата на капиталовия пазар, като се създава Българската фондова борса, която обединява няколко регионални борси и се учредява и „Централен депозитар“ АД. Въз основа на решението за масова приватизация на държавните предприятия, трансформирани в акционерни дружества в периода 1996-1997 г. се създават повече от 80 приватизационни фондове.

През 1997 г. Българската фондова борса се обединява със Софийска фондова борса, като наименованието на новата борса е „Българска фондова борса – София“ АД (БФБ). През същата година БФБ получава лиценз от КЦКФБ и на нея след мащабни промени през 1998 г. в ЗЦКФБИД и въвеждане на дефиниция за публично дружество (ПД) се листват всички публични дружества, в това число приватизираните чрез публично предлагане на акции държавни предприятия, преобразуваните в холдинги бивши приватизационни фондове и шестте инвестиционни дружества, създадени също въз основа на преобразуване на приватизационни фондове. Дотогава съществуват дружества, които са се търгували на фондова борса – през периода 1992-1996 това са около 80 дружества, за които обаче не е създаден специален режим. Поправката в ЗЦКФБИД дава едномесечен срок на дружествата, които отговарят на определението за ПД да подадат документи за вписване в регистъра на КЦКФБ. Основната причина за създаване на ПД е масовата приватизация и законовото ограничение приватизационните фондове да търгуват акции от масовата приватизация единствено и само на фондова борса (след отпадане на забраната за търговия). Акциите на около 1000 дружества преминават в притежание на няколко милиона инвеститори. За 1 година в регистъра на Комисията се вписват около 950 ПД – като почти всички са станали публични в резултат на масовата приватизация.

В този период лицензи получават и първите инвестиционни посредници, които още през 1997 г. учредяват своя браншова организация за защита на своите интереси – Българската асоциация на лицензираните инвестиционни посредници (БАЛИП).

В момента на БФБ се търгуват около 350 ПД, като от тях около 200 от своя страна са нисколиквидни. Техните акции са поименни, безналични и свободно прехвърляеми. Режимът на ПД е основан на пълна прозрачност и отчетност относно дейността и финансовите им резултати, като са създадени множество гаранции и защиты на правата

на акционерите, с особен акцент върху защитата на правата и интересите на миноритарните акционери.

В последващия период се приема действащият и понастоящем Закон за публичното предлагане на ценни книжа (ЗППЦК), основан на европейското законодателство в областта на регулирането на капиталовия пазар, а Комисията получава наименованието Държавна комисия по ценни книжа (ДКЦК).

През 2000 г. БФБ въвежда търговия на напълно автоматизираната търговска система RTS Plaza, като същата година създава борсовия индекс Sofix, а през 2003 г. Борсата създава интернет базирано приложение за достъп до БФБ в реално време – COBOS. От 2007 г. функционира електронната търговска система Xetra® на Дойче бърсе, която като търговска платформа на БФБ създава нови функционалности за ИП и техните клиенти. ЦД също въвежда нова система за търговия, позволяваща извършването на клиринг и сетълмент, като продължава да функционира като основен регистър на сделки и притежание на безналични ценни книжа.

Българският капиталов пазар се характеризира със сравнително кратка история и ниска ликвидност, особено през годините последвали световната икономическа криза от 2007 г. Регистрираните за търговия на БФБ София компании представляват голяма част от икономическите сектори от производствена индустрия през фармацевтични компании до представители на местния банков сектор.

Оценката на степента на развитие на българския капиталов пазар, и в частност на Българска Фондова Борса (БФБ)-София, може да бъде направен по много начини, но в случая ще се придържаме към възможно най-разбираем и общоприет следва да се прави като бъдат използвани следните общоприети показателя:

1. Брой листвани ценни книжа (компании) на фондовата борса;
2. Пазарна капитализация на борсата;
3. Дял на пазарната капитализация като процент от БВП;
4. Ликвидност (оборот) на фондовата борса;
5. Оборот на фондовата борса като процент от пазарната капитализация;
6. Степен на корелираност с останалите пазари

Броят на регистрираните емисии акции у нас (на официален и неофициален пазар) се запазва относително постоянен около цифрата от 350. Именно тези емисии са обект на активна търговия и определят оборота на фондовата борса у нас. Както е известно, броят на регистрираните емисии (дружества) за търговия на борсата е индикатор за размера на фондовата борса, и е пряко отражение на избрания метод на приватизация в отделните страни.

Пазарната капитализация на БФБ – София е една от най-ниските в региона, като към края на Юли 2019 г. е около 8.76 милиарда лева.

Стойността на капитализация на БФБ – София като процент от брутният вътрешен продукт на страната е около 12% и това е доста нисък показател, като за сравнение в развитите държави стойността на този показател надминава 100%, например за САЩ той е 138% към Август 2019 г. В Германия стойността му е около 49%, а за страните от централна и източна Европа варира около 20%.

Друг много важен показател за степента на развитие на капиталовия пазар е оборотът (ликвидността) на фондовата борса. За 2018 г. са се сключили малко над 50 000 сделки, в които са изтъргувани близо 172.5 милиона акции на обща стойност от 377.1 милиона лева. Би било безсмислено да сравняваме тези цифри с развити пазари, но ще отбележим, че в смятания за най-добре развит в района пазар на акции в Полша оборотът през 2018 г. е бил 54.75 милиарда долара, а в този на Унгария 9.9 милиарда долара.

Разглеждайки оборотът на фондовата борса като процент от пазарната капитализация (т.нар. коефициент за оборота), можем отново да видим, че най- високите

стойности за страните от региона са реализирани в Полша и Унгария - 34% и 34.2%, съответно. За България, цифрата е около 4%.

България е сред най-малко корелираните страни с останалите фондови борси на страните от Централна и Източна Европа. Този фактор е от изключителна важност и в условията на все по-глобално интегриран пазар влияе значително на отношението на инвеститорите.

Наред с тези общи показатели за степента на развитие и обемът на търговията на българския фондов пазар в сравнение с други подобни, и с цел да се онагледят фундаменталните разлики между него и останалите би трябвало да се слезне едно ниво надолу и да се разгледа „механиката“ на пазара, която е сред важните му градивни блокове. За съжаление това една от основните линии на слабост на родния пазар. Освен традиционния подход дадена акция да бъде закупена и впоследствие продадена на печалба или да бъде реализирана доходност от дивидентите, които разпределя на фондовата борса в България на практика не са налични други стратегии за търговия от които инвеститорите могат да се възползват. Причината за това е пословична. Слабата ликвидност и нисък оборот не позволяват наличието на традиционни способности за търговия, като маржин покупки (покупка на акции със заемен капитал чрез лостовия ефект) и къси продажби (продажба на акции без да са налични в портфейла на продавача им). Репо сделките (обезпечени с акции заеми) са рядкост а т.нар заем на ценни книжа е нормативно ограничен. Липсват борсово търгувани фондове (ETF's) базирани върху местни индекси или на определени инвестиционни стратегии. Това се промени с борсово търгувания фонд върху Sofix, учреден през 2016 г., чийто ефект върху пазара бе еднократен и незначителен. Съществена е липсата на търгувани деривативни продукти върху местните акции, като опции и фючърси.

Най-големите играчи на БФБ – София са собствениците или т.нар. мажоритарни акционери в компаниите, регистрирани за търговия, като традиционно, коефициентът на фрий флоут (свободни за търговия акции извън притежаваните от основния акционер) е доста нисък. Най-големите и влиятелни институционални инвеститори на родния пазар са частните пенсионни фондове, които към края на второ тримесечие на 2019 г. притежават акции на български емитенти на стойност 1.646 милиарда лева. Български договорни фондове са друг влиятелен инвеститор но, за техните активи и експозиция към български емитенти намаляха значително след световната икономическа криза през 2007 – 2008 г. и така и не възстановиха доверието на инвеститорите след спадовете от над 70% в нетната стойност на активите си, в сравнение с отбелязаните най-високи стойности. Чуждестранното присъствие на българската борса е доста ограничено и пасивно, като се свежда до няколко високорискови фонда за дялово инвестиране със скромнен размер. И накрая, дребните инвеститори, които са отговорни за голяма част от ежедневната търговия в днешни дни, съставени предимно от т.нар. спекуланти са най-малката съставна част на инвестиционната общност в България фокусираща се върху родния капиталов пазар.

Всичко това обуславя определянето на българския фондов пазар, като неразвит и неликвиден пазар.

Индексите изчислявани на БФБ-София включват емисии ценни книжа, търгувани на някой от организираните пазари, които отговарят на общите и специфичните критерии на съответния индекс и осигуряват точно отразяване на пазарните движения. В индексите могат да участват само емисии на публични дружества, които не са обявени в ликвидация или несъстоятелност, не изпълняват оздравителна програма и не са временно спрени от търговия. Минималният брой на емисиите, включени в индексите, е пет.

3.1 Пазари на БФБ-София

БФБ-София организира два пазара в зависимост от качествени и количествени критерии към емитентите и техните емисии финансови инструменти. Пазарите са сегментирани в зависимост от вида на ценните книжа, както и въз основа на специфични изисквания към емитентите по отношение на акционерната им структура, финансови показатели, ликвидност и разкриване на информация. Пазарите, организирани от БФБ-София, са изброени отдолу.

3.1.1 Основен пазар на Българска Фондова Борса (Bulgarian Stock Exchange или BSE) със следните пазарни сегменти:

Основният пазар на БФБ-София се състои от следните пазарни сегменти:

- Сегмент акции Premium;
- Сегмент акции Standard;
- Сегмент за борсово търгувани продукти;
- Сегмент за дружества със специална инвестиционна цел;
- Сегмент за държавни ценни книжа;
- Сегмент за облигации;
- Сегмент за компенсаторни инструменти;
- Сегмент за права;
- Сегмент за първично публично предлагане;

3.1.2 Алтернативен пазар на Българска Фондова Борса

Алтернативният пазар на БФБ-София се състои от следните пазарни сегменти:

- Сегмент акции;
- Сегмент за дружества със специална инвестиционна цел;

3.1.3 Финансови инструменти на БФБ-София.

На регулиран пазар могат да се търгуват единствено финансови инструменти, за чието прехвърляне не са предвидени ограничения или условия. Към момента на БФБ-София се търгуват следните видове финансови инструменти:

- Акции;
- Корпоративни и общински облигации;
- Компенсаторни инструменти;
- Сегмент борсово търгувани продукти;
- Права;
- Варанти;
- Сегмент за приватизация;
- Държавни ценни книжа.

3.1.4 Финансови инструменти на Основен пазар на БФБ-София

За да бъдат допуснати до търговия на някой от пазарите, организирани от Борсата, емисиите финансови инструменти трябва да отговарят на следните общи условия:

- Да са в безналична форма или да са обездвижени по съответния ред и да са регистрирани в депозитарна институция;
- Да отговарят на всички условия на ЗППЦК и нормативните актове по прилагането му относно публичното предлагане и допускането до търговия на регулиран пазар;
- За прехвърлянето им да не са предвидени ограничения или условия.

3.1.5 Индекси на БФБ

Представянето на един фондов пазар е прието да се описва най-добре чрез съставяне на т.нар. бенчмарки (базови показатели използвани за сравнение), въз основата на които да се измерва неговата възвръщаемост наричани борсови индекси. Тези борсови индекси са съставени от акции на различни емитенти в пропорции съответстващи на правилата за изчисляване и формират своята стойност на базата на стойността на акциите, включени в тях.

Към настоящия момент БФБ-София изчислява 4 собствени индекса – Sofix, BGBX40, BG TR30 и BG REIT. Основният борсов индекс е Sofix, като неговото изчисление започва на 20 октомври 2000 г. при базисна стойност от 100 пункта. Sofix е базиран на пазарната капитализация на включените 15 емисии обикновени акции, коригирана с фрий-флоута на всяка от тях. Емисиите в Sofix е необходимо да отговарят на определени изисквания за ликвидност, пазарна капитализация, фрий-флоут и брой акционери.

BG 40 е индекс, базиран на представянето на цените на емисиите и обхваща 40 емисии на обикновени акции на компаниите с най-голям брой сделки и най-висока средна стойност на дневния оборот през последните 6 месеца тъй като двата критерия имат еднаква тежест. Освен общите изисквания емисиите, включени в изчисляването на индекса, трябва да отговарят на следните допълнителни изисквания:

- Да бъдат допуснати до търговия на основния пазар на Българска фондова борса;
- Да бъдат търгувани на пазар, организиран от борсата, поне 3 (три) месеца преди въвеждането им в портфейла BG 40. При условие, че дадена емисия е прехвърлена за търговия от един пазарен сегмент на друг, датата на първото котиране на емисията се приема за първа дата на търгуване.

В случай на повече от три дружества, принадлежащи към една икономическа група, всички отговарящи на допълнителните изисквания по-горе, само трите емисии на дружества, принадлежащи към тази икономическа група, с най-голям брой сделки и най-висока средна стойност на дневния оборот се приемат в класацията. Ако в резултат на класирането се окаже, че две или повече емисии на дружества, принадлежащи към една икономическа група са класирани на едно и също място, емисиите с по-голям брой сделки, извършени през последните 6 месеца се третират с приоритет по отношение на включването.

Формулата за изчисляване на индекса BG40 е следната:

$$BG\ 40_t = BG\ 40_{t-1} \left[\frac{\sum_{i=1}^{40} P_{i,t} \times D_{i,t}}{\sum_{i=1}^{40} P_{i,t-1} \times D_{i,t-1}} \right] \times K \quad (29)$$

Където: $P_{i,t}$ е цената на последната сделка за i -тата ценна книга за деня t

$P_{i,t-1}$ е цената на последната сделка за i -тата ценна книга за деня $t-1$

$D_{i,t}$ е делителят за текущата търговска сесия за i -тата ценна книга;

K е коригиращият фактор ($K=1$, освен при промяна в базата на индекса)

$D_{i,t-1}$ е делителят за предходната търговска сесия за i -тата ценна книга;

Считано от 2 Януари 2014 година, БФБ - София АД спря да изчислява стойността на индексът BG 40 и започна да изчислява нов индекс на негово място наречен BGBX40. Начинът, по който BG 40 бе изчисляван водеше до различни деформации според местния борсов оператор. Например през март 2013 в BG 40 влезе компанията „ЧЕЗ Разпределение България“, която определяше 74% от стойността и движенията на индекса, според специализирания сайт Investor.bg. Причината е, че единичната цена на акция на дружеството е около 1500 лв., а на други големи компании, включени в индекса – около 3 лв. Заради тези недостатъци, ръководството на БФБ – София взе решение да се откаже от изчисляването на индекса. Новият индекс BGBX40 е доста близък до Sofix, като структура с разликата че обхваща 40 а не 15 компании. Той се базира на пазарната капитализация на включените емисии обикновени акции, коригирана с фрий-флоута на всяка от тях, като се състои от 40-те емисии обикновени акции на дружества с най-голям брой сделки и най-висока медианна стойност на дневния оборот за последните 6 месеца, като двата критерия имат еднаква тежест.

Индексът Sofix е базиран на пазарната капитализация на включените в него емисии обикновени акции, коригирани с свободно търгуемия обем от тях (Free float) на всеки от тях. Индексът покрива 15 броя акции, отговарящи на общите изисквания за избор на съставни емисии, които имат най-голямата пазарна стойност на свободния търгуемия обем. Всяка емисия, включена в базата данни на Sofix в допълнение към общите изисквания, трябва да отговаря и на следните критерии:

Емисиите да са допуснати до търговия на основния пазар на Българска фондова борса;

- Емисиите трябва да са били търгувани на пазар, организиран от Борсата, най-малко три месеца преди въвеждането им в портфейла на индекса Sofix. При условие, че даден емитент е прехвърлен за търговия от един пазарен сегмент на друг, първата дата на котиране на емисията се приема за първа дата на търгуване;
- Пазарната капитализация на емисията не може да бъде по-малка от 40 000 000 лв., А свободно търгуемия обем от тях не може да бъде по-малко от 25 на сто от общия обем на емисията или пазарната стойност на свободния търгуемия обем да не бъде по-малка от 10 000 000 лв.;
- Броят на акционерите в дадена емисия не може да бъде по-малък от 500 лица; Първите „n“ емисии (n е по-малко или равно на 30), отговарящи на изискванията за пазарна капитализация, с най-висока средна стойност на седмичния оборот и най-голям брой сделки през последната една година, като и двата критерия имат еднаква тежест, се допускат в класацията по втория критерии. Ако в резултат на

класирането по предходното изречение се получи, че две или повече емисии са класирани на едно място, емисията с най-голям брой сделките се третира приоритетно по отношение на включването.

$$SOFIX_t = SOFIX_{t-1} \times \left[\frac{\sum_{i=1}^n N_{i,t} \times P_{i,t} \times FF_{i,t} \times W_{i,t} \times D_{i,t}}{\sum_{i=1}^n N_{i,t-1} \times P_{i,t-1} \times FF_{i,t-1} \times W_{i,t-1} \times D_{i,t-1}} \right] \times K \quad (30)$$

Формулата за изчисляване на индекса Sofix е следната:

Където: $N_{i,t}$ е броят на акции в емисията на съответното дружество в деня t ;

$N_{i,t-1}$ е броят на акции в емисията на съответното дружество в деня $t-1$;

$P_{i,t}$ е цената на последната сделка за i -тата ценна книга за деня t

$P_{i,t-1}$ е цената на последната сделка за i -тата ценна книга за деня $t-1$

$FF_{i,t}$ е фрий-флоут коефициента на i -тата ценна книга за деня t

$FF_{i,t-1}$ е фрий-флоут коефициента на i -тата ценна книга за деня $t-1$

$W_{i,t}$ е тегловият коефициент на i -тата ценна книга за деня t ($W_i=1$, освен ако теглото на ценната книга би надхвърлило 15 % от индекса)

$W_{i,t-1}$ е тегловият коефициент на i -тата ценна книга за деня $t-1$

n е броят емисии, включени в индекса;

i е показателят за конкретната ценна книга;

t е денят, за който се изчислява индексът.

$D_{i,t}$ е делителят за текущата търговска сесия за i -тата ценна книга;

K е коригиращият фактор ($K=1$, освен при промяна в базата на индекса)

Окачествявайки българския капиталов пазар като ниско ликвиден и слабо развит пазар е редно да бъде даден нагледен и красноречив пример за това колко дълбока е т.нар. „пропаст“ между двата вида, описана в предходните редове. Затова в следващата таблица ще бъде направено едно наглед елементарно, но според автора много илюстративно сравнение. В Таблица 6 е показан действителна сделка осъществена на капиталовия пазар в САЩ:

Инструмент	SPDR Dow Jones Industrial Average ETF Trust
Вид Инструмент	Акция
Валута	USD
Тикер	DIA US Equity
Име	SPDR Dow Jones Industrial Average ETF Trust
Бр. за изълнение	121 587.00
Лимитиран цена	262.12
Обем в USD	31 870 384.44
Алгоритъм на изпълнение	SMRTR (Smart Route)
Подадена	14:37:27.700000
Изпълнена	14:37:57.511000
Време за изпълнение	29.8 сек.
Места н изпълнение	9 борсови пазара

Таблица 6: Данни за поръчка на капиталовия пазар в САЩ

Накратко, Таблица 6 показва изпълнение на сделка с борсово търгуван фонд, основан върху индекса Dow Jones Industrial Average, на стойност от малко под 32 милиона щатски долара (56.7 млн лв.), чрез използване на алгоритмична стратегия при лимитирана цена. Изпълнението на това нареждане отнема под 30 секунди, при положение че все пак е лимитирано откъм цена. При пазарна поръчка със същия обем, би могло да се очаква многократно по-бързо изпълнение. В процеса на изпълнение на поръчката, сделки се сключват на 9 организирани пазара едновременно, а влиянието върху цената на финансовия инструмент е пренебрежимо малко.

В същото време, целият оборот на БФБ – София за периода Януари – Март 2019 г. е в размер на 99.67 млн. лв.

3.2 Задание за прогнозиране

След изчерпателното описание на структурата, основните характеристики на механиката на българския фондов пазар идва логичния въпрос какъв би бил най-подходящият обект на изследване, свързан с него, чрез помощта на техниките на изкуствения интелект и машинно обучение и по-конкретно с невронни мрежи. Възможностите тук са няколко, като според автора, изборът може да се сведе до две реални алтернативи: да бъде направен опит за прогнозиране на бъдещата стойност или възвръщаемост на на индивидуални акции, регистрирани за търговия на БФБ или да бъде прогнозирана стойността или изменението на борсов индекс, съставен от акции. Авторът се е насочил към втората възможност, за да не се налага да се избира измежду голям брой акции, които да бъдат обект на по-задълбочено изследване или да бъде направен по-ограничен експеримент върху голям брой от инструменти. Освен това тенденцията в подобни експерименти сред разгледаната литература е отчетлива в полза на борсовите индекси, като измерители на широкия фондов пазар, което дава възможност да се постави и изпитание хипотезата за ефективния пазар.

Основните цели пред авторът на дисертационния труд бяха да се изследва формирането, развитието и способността на изкуствения интелект и по-конкретно изкуствените невронни мрежи за целите на прогнозиране на динамични системи като финансовите пазари. Също така, да бъде направен подробен очерк на развитието в областта на прогнозиране на финансовите пазари с изкуствени невронни мрежи през годините. Освен това, вече бе направено и представяне на българския фондов пазар и беше мотивирано изследването му с цел прогнозиране.

Цел на прогнозиране ще бъде основния индекс на родния пазар - Sofix [120]. Sofix е базиран на пазарната капитализация на включените 15 емисии обикновени акции, коригирана с фрий-флоута на всяка от тях. Емисиите в Sofix е необходимо да отговарят на определени изисквания за ликвидност, пазарна капитализация, фрий-флоут и брой акционери.

Сега идва ред да бъде изграден модел за прогнозиране на базата изкуствени невронни мрежи, като на този етап ще бъде имплементирано цялото придобито знание и опит от предходните глави, за да може успешно да бъдат избрани най-подходящите параметри на модела за прогнозиране, като: вид и архитектура на невронна мрежа, вида на алгоритъма за обучение, вида на активиращата функция, начина, продължителността и интензитета на процеса на обучаване на мрежата. Не по-малко важен е избора на входящите параметри, тяхното откриване, преглед и предварителна подготовка и подходящо разпределение на подгрупи. Като част от процеса по обучение и изпитване на невронни мрежи, определянето на измерител на тяхното представяне – на стойността на грешката също има голяма важност. От значение ще бъде, след като бъдат получени някакви резултати да бъдат направени подходящи корекции на модела, за да бъдат

подобрени способностите му. След като бъдат получени окончателните резултати от експериментите, те да бъдат анализирани, сложени в перспектива и сравнени с други подобни и не на последно място интерпретирани. И накрая, да бъдат направени обосновани заключения и да бъдат поставени цели за бъдещо допълване и развитие на моделите за прогнозиране.

За прогнозиране на Sofix е избран най-широко разпространения и използван за моделиране на времеви серии от финансови данни модел на невронна мрежа с предавана напред сигнал - многослоен перцептрон. Както вече бе споменато, освен че се радва на голяма популярност в изследователската общност, обратната връзка, получена от голяма част от авторите бе положителна. При това положение, авторът няма как да не се изкуши да изпробва способностите на модел станал една от причините за бурното развитие в областта и в този труд. При представянето на статистическите показатели от прегледа на разработките в тази сфера бе установено, че многослойният перцептрон е убедителен водач по брой изследвания в които е използван и няма изявена мрежова структура която да се доближава до него, което прави избора на модел с който да се експериментира относително лека задача за автора.

3.2.1 Избор на данни

Данните използвани за проучването, са от официалния сайт на Българска фондова борса и се състоят от следната информация за индекса Sofix: последна стойност, стойност на отваряне, най-висока стойност за деня, и най-ниска стойност за деня, като и изтъргувания обем. Освен ценовата информация в експеримента се използват пет от най-често срещаните технически индикатори: 30-дневна подвижна средна, 60-дневна подвижна средна, 200-дневна подвижна средна, 14-дневния индекс на относителната сила и 30-дневния индекс на относителната сила. Всички данни са за периода между 04.01.2010 г. и 28.02.2013 г. Изборът на този период не е случаен, тъй като в него се наблюдават трите основни състояния на фондовия пазар. В началните няколко месеца индекса Sofix се намира във възходящ тренд, за които фигуративно описано са характерни по- високи дъна и по- високи върхове от предишните му такива. След това индекса навлиза в низходящ тренд, за които са характерни по ниски дъна и по-ниски върхове от предишните му такива. След това се наблюдава и фаза на консолидация на индекса, която се характеризира най-точно с липса на явна посока на движение на цената. В последната фаза на избраните данни отново се наблюдава възходящ тренд. Смята се, че след като на мрежата бъдат предоставени тези данни за обучение, тя ще може да разчете скритите зависимости между тези параметри.

След първоначалната селекция на данни, избраните такива са разделени на три части, като половината от тях се ползват за фактическото обучение, а останалата част е разделена между данни за изпитване и данни за валидиране или: данни за обучение – 50%, данни за изпитване – 25% и данни за валидиране – 25%.

Графика на движението стойността на индекса за периода е показана на Фигура 10 отдолу.



Фигура 10: Графика на стойността на индекс Sofix

Както е видимо от представената графика, разглеждания период разполага със всички необходими според автора шаблони на наблюдавани тенденции в движението на един индекс, които да послужат за добро обучение на мрежата. Смята се че след като на модела се представят типични примери за трите основни състояния на финансовите пазари и по-конкретно на тези на акции, а именно: възходящ тренд (характерен с по-високи върхове от предишните и по-високи дъна от предишните), консолидационна фаза (пазарът не може да намери ясна посока) и низходящ тренд (характерен с по-ниски върхове от предишните и по-ниски дъна от предишните), той ще може да разпознава силите и взаимовръзките, които предоставят зараждането и продължителността на подобни движения на база на нова информация, която да му бъде предоставена. В първата част от наблюдавания период, българския фондов пазар се намира в възходящ тренд, като индексът се покачва с повече от 23% за около месец. В края на наблюдавания период се наблюдава първо възходящ с покачване на индекса от над 26% за около месец и половина и веднага след това последва силна корекция в стойността му от 11% в рамките на няколко дни

3.2.2 Избор на архитектура и обучение на невронните мрежи

Използвания за изследването разновидност на изкуствени невронни мрежи е многослоен перцептрон. Той използва алгоритъма с обратно разпространение на грешката и алгоритъма на конюгирано градиентно спускане за обучение, като в случая е използвана онлайн версията на алгоритъма на обратно разпространение на грешката, при която се изчисляват локалните градиенти на всяко едно от теглата за всеки един случай по време на обучението, като същите се променят веднъж за всяко обучение. Теглата на връзките между невроните се променят по веднъж на всяко преминаване на информацията за грешката.

Формулата за тяхното промяна е следната:

$$\Delta \omega_{ij}(t) = \eta \delta_j o_i + \alpha \Delta \omega_{ij}(t-1) \quad (31)$$

Където:

η – степента на обучение;

δ - локалният градиент на грешката;

α - коефициент за инерция;

o_i – резултата на i -тия елемент.

Праговете се третираат като тегла, както следва $o_i = -1$. Изчисляването на локалния градиент на грешката зависи от това дали единицата, в която се подава теглото е в изходния слой или в скритите слоеве. Локалните градиенти в изходните слоеве са продукт на производните на функцията за грешка на мрежата и функциите за активиране на единиците. Локалните градиенти в скрити слоеве представляват претеглената сума на изходящите тегла на дадена единица и локалните градиенти на единиците, към които тези тегла се свързват.

Конюгираното градиентно спускане [121],[122] представлява усъвършенстван метод за обучение на многослойни перцептрони. Обикновено той се представя значително по-добре от метода на обратно разпространение на грешката и може да се използва навсякъде, където може да бъде използвано обратното разпространение. Тази техника е предпочитана за мрежи с голям брой тегла (повече от няколко стотин) и/или множество изходни единици. Конюгираното градиентно спускане е алгоритъм за обновяване на партиди, докато обратното разпространение регулира теглото на мрежата след всеки случай, конюгираното градиентно спускане изчислява средния градиент на повърхността на грешките във всички случаи, преди да актуализира теглата веднъж в края на епохата на обучение. Той е значително по-бърз при решаването на много проблеми, но алгоритъма с обратно разпространение на грешката все още има предимства при някои обстоятелства и е най-лесният алгоритъм за разбиране.

В процеса на обратно разпространение се изчислява градиентният вектор на повърхността на грешката. Този вектор насочва в посока на най-стръмно спускане от текущата точка, затова ако се движим по него дори в продължение на кратко разстояние, ще намалим грешката. Последователност от такива движения (забавящи се при близост до дъното) в крайна сметка ще намерим някакъв минимум. Трудната част е да се реши колко големи трябва да бъдат стъпките. Големите стъпки могат да приближат по-бързо минималната стойност на грешката, но също така могат да я пропуснат или (ако повърхността на грешката е много ексцентрична) да излязат в грешната посока. Класически пример за това в обучението на невронни мрежи е, когато алгоритъмът се развива много бавно по стръмна, тясна долина, от едната страна към другата. За разлика от тях много малки стъпки могат да вървят в правилната посока, но за сметка на това изискват голям брой повторения. На практика, размерът на стъпката е пропорционален на наклона (така че алгоритмите да се установят в най-ниската точка) и на специална константа - скоростта на учене. Правилната настройка на скоростта на обучение зависи от приложението и обикновено се избира чрез експеримент. Също така може да бъде различна във времето, като намалява с течение на времето докато алгоритъмът обучава.

Обикновено, алгоритъмът се модифицира чрез включване на инерционен момент в обучението. Това насърчава движението в определена посока, така че ако се предприемат няколко стъпки в същата посока, алгоритъмът повишава скоростта си, което понякога му дава възможност да избяга от локалните минимума, както и да се

движи бързо по плоски петна и плата. Следователно, алгоритъмът напредва итеративно през няколко цикъла на обучение, наречени епохи. Във всяка епоха детайлите на обучението се предават от своя страна на мрежата и целевите и действителните резултати се сравняват и се изчислява грешката. Тази грешка, заедно с градиента на повърхността на грешката се използва за коригиране на теглата, а след това целият процес се повтаря. Първоначалната мрежова конфигурация е случайна, а обучението спира когато изтече определен брой епохи, когато грешката достигне приемливо ниво или когато грешката спре да се подобрява.

Един основен проблем с този начин на обучение е, че той всъщност не намалява грешката, която наистина представлява интерес - каквато е очакваната грешка, която мрежата ще направи, когато и бъдат представени нови случаи, различни от тези с които е обучавана. С други думи, най-желаната способност на дадена мрежа е умението ѝ да обобщава или генерализира в нови ситуации. В действителност, мрежата е обучена да сведе до минимум грешката в тренировъчния комплект данни. Освен че няма перфектен и безкрайно голям набор от тренировки, обучението не представлява заучаване на способността за минимизиране на грешката върху реалната повърхност на грешката, а само върху тази на ползвания за обучение шаблон.

Най-важното проявление на това разграничение е проблемът с прекомерното обучение или т. нар. „Over-fitting“. Изкуствена невронна мрежа с повече тегла моделира по-сложна функция и следователно е склонна към прекомерно обучение. Мрежата с по-малки тегла може да не е достатъчно мощна, за да моделира основната функция. Например мрежа без скрити слоеве всъщност моделира обикновена линейна функция.

По-голямата мрежа почти винаги ще постигне по-ниска грешка, но това може да означава прекомерното обучение и напасване към данните, а не добро моделиране. Поради тази причина данните за обучението са разделени на три части, за да може да се проверява напредъка спрямо независим набор от данни, невидим за мрежата. Това са вече определените набори от изпитващи и валидиращи данни за мрежата, които са разпределени, както вече бе описано в пропорция 50%/25%/25%. Целта на това разпределение е, от една страна да бъде избегнато прекомерното обучение и продуктивността на мрежата да бъде изпитана върху по-масивен тестови шаблон.

Този процес работи като част от първоначалната база данни се запази, а не се използва за обучение в алгоритъма за обратно разпространение. Вместо това тези данни се използват, за да водят независима проверка на хода на обучението. Първоначалното представяне на мрежата върху сетовете за обучение и изпитване е същото (ако представянето на мрежата не е приблизително еднакво, разделянето на сетовете от данни между компонентите вероятно е уклончиво). Докато обучението напредва, грешката от обучението пада и ако обучаващия алгоритъм счете, че обучението минимизира действителната функция на грешката, то и грешката при изпитващия сет следва също да пада. Ако обаче грешката в селекцията спре да пада или пък започва да се покачва, това означава, че мрежата започва да се обучава прекомерно с данните и обучението трябва да спре. Поради тази причина в изследването се използва софтуерно решение, което прави така, че обучението да спре автоматично, след като грешката в обучението започне нараства, но следи причината за това да не е изпадане в локален минимум.

При прекомерно научаване на мрежата по време на процеса на обучение, обикновено се препоръчва да се намали броя на скритите единици и/или скритите слоеве, тъй като мрежата е прекалено мощна за конкретния проблем. За разлика от това, ако мрежата не е достатъчно мощна, за да моделира (разполага с по-малко от необходимия оптимален брой единици и скрити слоеве) основната функция, няма да се стигне до прекомерно обучение, но нито грешките при обучението, нито грешката при изпитване ще паднат до задоволително ниво.

Проблема с повтарящи се експерименти за изпитване на мрежата е, че наборът от бази данни играе ключова роля при избора на модел, което означава, че той всъщност е част от процеса на обучение. Поради тази причина неговата надеждност като независим измерител на представянето на модела може да бъде компрометирана. Изпълнявайки достатъчно експерименти може дори случайно да се натъкнем на една „късметлийска“ мрежа, която се справя добре в селекцията. За да се добави допълнителна доза доверие в представянето на окончателно избрания модел, практиката е да се отдели трети набор от данни за валидиране, като е добре това да се прави, когато обемът на данните за обучението го позволява. Окончателният модел се тества с данните от валидиращия набор, за да се гарантира, че резултатите от обучението и изпитването му са реални. Разбира се, за да бъде изпълнена тази роля успешно, валидиращия набор трябва да се използва само веднъж. Ако и той на свой ред се използва за коригиране на параметрите на мрежата и повтаря процеса на обучение, то процеса се превръща в подбор на данни. Процеса на разделяне на данните е силно субективен и в теорията съществува различни различни теории за това как е редно да бъде проведен. Този проблем може да преодолее, чрез прекласифициране на отделните бази данни. Експерименти могат да се извършват, като се използват различни селекции на наличните данни в обучаващи, изпитващи и валидиращи групи. Съществуват редица подходи към това преобразуване на подмножествата, включително на случайни пресмятане(Монте-Карло), кръстосано валидиране и зареждане (bootstrap). Чрез вземането на добри решения от експериментиращия, относно най-добрата конфигурация на невронната мрежа, която да се използва за експерименти с най-различни подмножества данни, продуцираните резултати могат да бъдат много по-надеждни. Так ще може да се реши по-точно кои видове мрежи да се използват и обучават на ново с нови примерни данни само тези мрежи, като по този начин се премахва каквото и да е пристрастие в отделните извадки. Друг подход е да се запазят само най-добрите мрежи, намерени по време на процеса на изпитване и валидиране, на база на различни извадки, но техните резултати да бъдат осреднени, което да намали субективния фактор при разпределението на данните от данни.

Всичко описано дотук е един изключително времеемък и изискващ ресурс процес, който е добре да бъде спомаган от интелигентен модул за разрешаване на проблеми и експериментира с различен брой скрити единици, комбинации от входни променливи, да изпълнява редица обучена с всяка тествана мрежова архитектура, да избира най-добрата мрежа въз основа на грешка в обучението и валидирането. Софистицираните алгоритми за търсене на интелигентния модул за разрешаване на проблеми, използващи усъвършенствани концепции като анализ на чувствителността и процеси на въвеждане на допълнителна информация за решаване на неправилно поставен проблем, могат да тестват стотици комбинации от мрежи, като се концентрират върху особено обещаващи мрежови архитектури и намерят бързо решения. По този начин добре подбрани, качествен и високо производителен софтуерен продукт премахва немалка част затрудненията на изследователя. За настоящия експеримент, авторът на дисертационния труд се е спрял на продукта STATISTICA 7 Neural Networks [123].

3.2.3 Активираща функция и оценка на грешката

Най-често използваните активационни функции при невроните в многослойния перцептрон са сигмоидната и хиперболичната функции. Авторът на този труд използва сигмоидална активационна функцията, която се изразява по следния начин:

$$E(t) = \frac{1}{1 + e^{-t}} \quad (32)$$

Грешката на определена конфигурация на мрежата може да се определи, когато бъдат изпълнени всички цикли на обучение на мрежата, сравнявайки реалната генерирана прогнозирана стойност с желаните или целевите резултати. Разликите се комбинират чрез функция за грешката, за да се изчисли мрежовата грешка. Най-често срещания измерител на грешката (използвана за регресионни проблеми), е средната квадратична грешка където отделните грешки на изходните единици във всеки случай са повдигнати на квадрат и сумирани заедно. Невронните мрежи в случая ще отчитат своята RMS, нормализирана за броя на случаите и променливите, под квадратен корен. Това обобщава грешката в целия набор от обучения и изходни единици.

Изкуствените невронни мрежи ще бъдат оценени на база на определен критерий, който в случая ще бъде грешката на мрежата при подмножествата, използвани по време на обучението – средно квадратичната грешка (RMS - Root Mean Square), изразена по следния начин:

$$RMS = \sqrt{\frac{\sum_{i=1}^n (\hat{\delta}_i - \delta_i)^2}{n}} \quad (33)$$

Където: δ_i' прогнозираната величина
 δ_i е целевата величина

Тази мярка е малко по-трудна за интерпретиране от измерването на ефективността, но представлява, фактически оптимизираната от тренировъчния алгоритъм стойност (поне за подгрупата използвана за обучение). Това е средноквадратичната стойност на грешките в мрежата за отделните случаи, при които отделните грешки се генерират от функцията за грешка в мрежата, която или е функция на наблюдаваните и очакваните изходни нива на активиране на невроните (обикновено сума от квадрати или мярка за кръстосана ентропия); или сума от квадрати. Грешката е сумата от квадратите на разликите между целевите и действителните стойности на изхода на всеки изходен елемент. Това е стандартната функция за грешка, използвана в регресионни проблеми.

3.2.4 Резултат от първи експеримент

Теглата на връзките между невроните и тяхното „отместване“ – (bias, или описан по-рано в този труд, като вътрешно съпротивление на всеки отделен неврон, като друго често използвано име е прагов елемент) в мрежата автоматично се инициализират от софтуера, като малки произволни числа.

Тъй като множество автори препоръчват, за да не се затормозява конструирания модел и да се забавя допълнително времето му за изчисляване данните, които се подават да бъдат с по-малък разряд, бе отчетено като необходимост данните да бъдат реорганизирани от стойности в дневна промяна на първоначалните стойности. Това се обуславя от броя на входящите променливи, които са десет за период от две години и два месеца. В разглеждания период от време индексът варира между минимална стойност от 286.03 и максималната стойност от 455.75, а средната му стойност е 365.29.

Първоначалните резултати от изследването не са особено добри. Те показват една интересна тенденция, а именно, че мрежите, които използват всичките десет входящи параметъра (последна цена, цена на отваряне, най-висока, най-ниска цена, изтъргуван обем, 30-дневна плъзгаща средна, 60-дневна плъзгаща се средна, 200-дневна плъзгаща се средна стойност, 14-дневния индекс на относителната сила и 30-дневния индекс на относителната сила), постоянно се представят много по-лошо от тези, които изолират някои от входящите параметри. Моделите, които основават своите прогнози единствено на последната цена, показват най-добри резултати по отношение на грешката при обучение. Освен това в нито един случай, мрежа с повече от един скрит слой не се представи по-добре такава с един скрит слой.


Изпробвани бяха няколко вида архитектура, като най-добре представилата се изкуствена невронна мрежа бе с три слоя, с един елемент във входния слой, отговарящ за параметъра промяна на последната цена, който бе крайна цел на прогнозиране и използваща 43 стъпки назад във времето. Този модел притежава, 7 елемента в скрития слой, и един елемент в изходящия слой, отговарящ на прогнозираната променлива на входа. Структурата бе избрана с помощта на функцията за оптимизиране на структурата на моделите налична в прилагания софтуерен продукт, като това приложение се доказва като по-ефективно и много по-бързо от ръчните настройки правени от автора. Обучението на най-добре представилата се на този етап мрежа включва 100 цикъла (епохи) на обратно разпространение и 23 цикъла на конюгирано градиентно спускане. Това доведе до грешка при изпитване от 0.119279, което на пръв поглед може да обуслови две заключения. Първото е, че мрежата не е била прекомерно обучена и второ - резултатът определено не изглежда впечатляващо.

След като бяха взети предвид постигнатите първоначални резултати от които е видно, че трябва да се нанесат някакви корекции в модела, поради което авторът се насочи към входящите данни. Вземайки предвид особеностите на българския пазар на акции и по-специално неговата неликвидност, която позволява отделни сделки, не изпълнени на чисто пазарен принцип да влияят върху цялостната стойност и изменение на индекса бе сметнено за удачно да предприемат допълнителна предварителна обработка на данните под формата на осредняване на входящите стойности, респективно измененията на индекса като се започне от 3 дневно осредняване. Резултатите от така проведените експерименти са представени в следната таблица.

	Network structure Input-hidden-output	Learning samples BP/CGD	Test error RMS
3 days smoothing	1(12)-5-1	BP-100; CGD-115	0.076298
4 days smoothing	1(12)-11-1	BP-100; CGD-58	0.089827
5 days smoothing	1(25)-15-1	BP-100; CGD-48	0.067025
6 days smoothing	1(10)-5-1	BP-100; CGD-76	0.075116
7 days smoothing	1(20)-13-1	BP-100; CGD-34	0.057099
8 days smoothing	1(15)-14-1	BP-100; CGD-68	0.057903
9 days smoothing	1(15)-5-1	BP-100; CGD-67	0.064887


Таблица 7: Резултат след осредняване на дневните данни

Видно от резултатите в таблицата е, че извършеното осредняване дава резултат и успява да намали грешката при валидацията на данни значително. Наблюдава се тенденцията, грешката да продължава да намалява със удължаване на периода на осредняване до 7 дни. След това грешката започва отново да нараства и губи и продължаване на осредняването губи смисъл. Невронната мрежа, показала най-добър резултат под формата на най-малка стойност на грешката при валидиране от 0.057099 е изградена от един входящ слой (и тук отново се потвърждава тенденцията за по-добро представяне на мрежи използващи като входящи данни само прогнозирания параметър), 13 неврона в скрития слой и един изходящ елемент. Обучението е извършено на база на 34 епохи конюгирано градиентно спускане и 100 епохи обратно разпространение и данни за 20 стъпки назад във времето. Видно от таблицата е че епохите на обучение чрез обратно разпространение на грешката се ограничени до 100 броя, поради времеемкостта на този вид обучение и липсата на по-добри резултати при провеждане на експерименти без да бъде зададен максимален брой цикли. Фигуративно представяне на най-добре представилата се невронна мрежа е показана на Фигура 11




Фигура 11: Многослоен перцептрон с 10 входа, 13 неврона в скрития слой и един изходен елемент

На Фигура 12 са показани прогнозираните резултати спрямо действителните наблюдения на многослоен перцептрон с 10 входа, 13 неврона в скрития слой и един изходен елемент




Фигура 12: Диаграма на прогнозираните резултати спрямо действителните наблюдения.

Графика на прогнозираната стойност и на наблюдаваната в действителност е представена на следващата Фигура 13.



Фигура 13 Графика на прогнозираните стойности спрямо действително наблюдаваните за валидиращите данни

Диаграма на остатъчната грешка на многослоен перцептрон с 10 входа, 13 неврона в скрития слой и един изходен елемент по време на целия процес е представена на Фигура 14.



Фигура 14: Диаграма на остатъчната грешка

От графиката на остатъчната грешка, показана на Фигура 14 може да се види една интересна тенденция. В началото на периода и неговия край се наблюдава ръст на размера на грешката, който може да бъде обяснен със състава на входните данни, представени на изкуствената невронна мрежа. В първата част от наблюдавания период, българския фондов пазар се намира във възходящ тренд, като индексът се покачва с повече от 23% за около месец. В края на наблюдавания период се наблюдава първо възходящ с покачване на индекса от над 26% за около месец и половина и веднага след това последва силна корекция (рязко отдръпване от постигнати високи стойности) в стойността му от 11% в рамките на няколко дни, което според автора води и до наблюдавания на графиката скок в отклонението на предвижданията на мрежата спрямо действителните стойности на Sofix.

Обяснението на тези резки движения в стойностите на акциите, част от представителния индекс на българския фондов пазар може да бъде, че в условията на ниска ликвидност порядъка на всяко движение се мултиплицира. Тези големи амплитуди в стойността на индекса са известни с термина волатилност на цените, като тенденцията при този показател е да се повишава в периоди когато пазара се намира в тренд и особено много в такива на низходящ тренд, при който цените на акциите, съответно стойността на Sofix преминават през продължителен период на намаление. От това наблюдение може да се направи заключението, че изкуствените невронни мрежи се представят добре когато прогнозира на базата на времеви серии от информация за пазари в консолидираща фаза и губят точност на прогнозите си в условията на тренд, като това е особено силно изразено при низходящ тренд.

Друго наблюдение от проведения експеримент на база на осреднените данни е продължаващото по-лошо представяне на невронните мрежи, използващи пълния набор от параметри за обучение, изпитване и валидиране, съставен от 10 параметъра. Най-добър резултат бе постигнат от модел, използващ 9 от променливите, с осреднени стойности за 7 дни. Мрежата бе изградена от 9 входни елемента, отговарящи за деветте използвани променливи, 21 неврона в скрития слой и едни елемент в изходния слой, обучени на базата на 100 цикъла обратно разпространение на грешката и 81 цикъла конюгирано градиентно спускане. Постигнатия резултат за средната квадратична грешка е 0.068935 и продължава да се счита за не достатъчно добър, особено като се вземе предвид по-сложната структура на невронната мрежа и повечето време, необходимо за обучението ѝ.

В заключение, резултатът от проведения експеримент може да бъде определен като задоволителен, въпреки неубедителните първоначални опити, след няколко манипулации на входните данни, чрез осредняване на данните за до 9 дни и на мрежовата архитектура, чрез изолиране на възможността за повече от един скрит слой и използване на един елемент във входящия слой, респективно само на прогнозираната променлива бе постигнато значително подобрене в стойността на грешката на модела. Направено бе полезно наблюдение, че способността на модела на многослоен перцептрон да прогнозира стойност на индекс на неликвиден пазар на акции при наблюдаван тренд в данните за обучение и особено в случай на много висока волатилност в следствие на низходящ такъв ерозира в сравнение с данни, произтичащи от пазар в консолидационна фаза.

Вероятно предизвикателството да бъде прогнозиран високо волатилния и ниско ликвиден борсов пазар на акции в България може да бъде поставено пред друг тип невронна мрежа, за да бъде проверено популярното схващане, че моделът на многослоен перцептрон е за предпочитане, когато се прогнозира времеви серии финансови данни.

3.2.5 Експеримент върху два индекса с различни мрежови архитектури

След направеното не еднозначно заключение за проведения експеримент с най-широко разпространената архитектура на изкуствена невронна мрежа в следващите редове ще бъде направен нов опит за прогнозиране на българския фондов пазар чрез невронни мрежи, но този път в занятието ще бъдат включени два нови вида мрежи, а именно изкуствените невронни мрежи с радиална базова функция и изкуствени невронни мрежи с обща регресия [124].


С кратък очерк, тези два модела ще бъдат представени преди да се премине към същинската част на експеримента.

3.2.5.1 Невронни мрежи с радиална базова функция

Вторият тип невронна мрежа, използвана в описания по-долу експеримент е невронната мрежа с радиална базова функция. Това е мрежа, която използва радиална базова функция, като активираща функция. Изходът на мрежата е линейна комбинация от радиални базови функции на входовете и невронните параметри. Типичната радиална функция е Гаусовата функция, нейната основна характеристика е, че нейния отзивчивост намалява (или нараства) монотонно с разстоянието от централната точка. Тази тип мрежи имат редица предимства пред мултислоевите перцептрони. Първо, те могат да моделират всяка нелинейна функция, използвайки един скрит слой, който премахва

някои от въпросителните относно архитектурата на мрежата и по-специално за броя на скритите слоеве. На второ място, простата линейна трансформация в изходния слой може да бъде оптимизирана напълно, като се използват традиционните техники за линейно моделиране, които са бързи и не страдат от проблеми като този да попадат в локални минимума, от които често страдат техниките за обучение на многослойни перцептрони. Мрежите с радиални базови функции могат да бъдат обучени изключително бързо.

След като се знае как многослойния перцептрон моделира функцията на отговор, чрез използването на функции, като сигмоидни, стъпаловидна и прагова за различни проблеми, това образно качано, съответства на разделянето на пространството на шаблона с помощта на хипер плоскости (hyperplanes)[125]. Използването им за разделяне на пространството е естествен подход, интуитивно привлекателен и базиран на основната простота на линиите. Еднакво привлекателен и интуитивен подход е да се раздели пространството чрез кръгове или хиперперсфери. Хиперсферата се характеризира със своя център и радиус. По-общо казано, точно както многослойния перцептрон реагира нелинейно на разстоянието от точки до линията на сигмоидния праг, при мрежа с радиална базова функция [51],[126] реагира нелинейно на разстоянието от точки до центъра, представен от радиалния елемент. По този начин повърхността за отговор на единична радиална единица е Гаусова функция (има форма на звънец), достигаща връх в центъра и спускаща се навън. Точно както стръмнината на сигмоидните криви при многослойния перцептрон може да бъде променена, така може да се промени и наклонът на Гаусовия радиален блок. Формата на Гаусовата функция е показана на Фигура 15.



Фигура 15: Форма на Гаусова функция

Гаусовата функция е:


$$f(x) = ae^{-\frac{(x-b)^2}{2c^2}} \quad (34)$$

Където: a , b и c - различно от 0 са реални произволни числа

Съставните единици на мултислоевите перцептрони се определят от техните тегла и прагове, които се комбинират, за да дадат уравнението на дефиниращата линия и степента на падане на функцията от тази линия. Преди приложението на сигмоидалната функция за активиране, нивото на активиране на всяка една единица се определя с помощта на претеглена сума, която математически представлява скалирано произведение на входния вектор и тегловния вектор на единицата. В използвания за експеримента софтуерен продукт STATISTICA невронни мрежи, тези звена са означени като единици на скалирано произведение. Не точно така седят нещата при мрежите с радиална базова функция, радиалният елемент се определя от неговата централна точка и радиус. Точка в N - измерното пространство се определя с N брой номера, които точно съответстват на броя на теглата в единица на скалирано произведение, така че центърът на радиалната единица се съхранява в софтуерния продукт, като тегло. Стойността на радиуса или отклонението се записва като праг. Струва си да се подчертае, че теглата и праговете в една радиална единица, всъщност са напълно различни от тези в единица на скалирано произведение, а терминологията може да бъде опасна, ако не се съобразява следното заключение: Радиалните тегла действително образуват точка и радиалния праг е действително едно отклонение.

Поради тази причина, изкуствените невронни мрежи с радиална базова функция, притежават скрит слой от радиални единици, всеки от които всъщност моделира Гаусовата повърхнина на отговор. Тъй като тези функции са нелинейни, всъщност не е необходимо да има повече от един скрит слой, за да се моделира всяка форма на функция, напротив, задоволителен брой радиални единици винаги ще бъдат достатъчни, за да моделират всяка функция. Оставащият въпрос е как да бъдат комбинирани изходите на скрития радиален блок в мрежовите изходи? Оказва се, че е достатъчно да се използва линейна комбинация от тези изходи (т.е. претеглена сума от Гаусовите), за да се моделира всяка нелинейна функция. Следователно, стандартната мрежа с радиална базова функция има изходен слой, съдържащ единици на скалирано произведение с функция за активиране на идентичността [126], Бишъп[121].

Изкуствените невронни мрежи с радиална базова функция имат редица предимства пред многослойните перцептрони. Първо, те могат да моделират всяка нелинейна функция, използвайки един скрит слой, който премахва необходимостта от сложни решения за архитектурата на мрежата и за броя на слоевете. На второ място, простата линейна трансформация в изходния слой може да бъде оптимизирана напълно, като се използват традиционните техники за линейно моделиране, които са бързи и не страдат от проблеми като локалните минимума, които нарушават работата на техниките за обучение на многослойните перцептрони. Следователно мрежите с радиална базова функция могат да бъдат обучени изключително бързо. На Фигура 16 е представен начин по който невронни мрежи с радиална базова функция се представят схематично.



Фигура 16: Невронна мрежа с радиална базова функция

От друга страна, преди да може да се приложи линейна оптимизация на изходния слой на мрежи с радиална базова функция, трябва да се реши броят на радиалните единици, а след това техните центрове и отклонения трябва да бъдат определени. Въпреки че са по-бързи от тези използвани за обучението на многослойните перцептрони, алгоритмите наточени с тази задача са еднакво склонни да открият неоптимални комбинации. За да компенсира този недостатък, използваното софтуерно решение притежава модул наречен „Intelligent Problem Solver“, който е в състояние да улесни задачата, като изпълни неизбежната експериментална фаза автоматично.

Други често срещани в литературата характеристики, които отличават представянето на мрежите с радиална базова функция от тази на многослойните перцептрони се дължат на различните подходи към пространството за моделиране, където мрежите с радиална базова функция са определяни като "тежки и не-елегантни", а многослойните перцептрони са наричани "плоски".

Опитът показва, че по-ексцентричната повърхност на реакция на мрежите с радиална базова функция изисква много повече единици, които да моделират адекватно по-голям брой видове функции. Разбира се, винаги е възможно да се проектират форми, които най-лесно се представят по един или друг начин, но балансът не е в полза на РБФ мрежите. Следователно, решението на мрежите с радиална базова функция ще бъде склонно да се изпълнява по-бавно и да използва повече пространство от съответното решение, продуцирано от многослоен перцептрон, но е много по-бързо да се обучи, като това се счита по-скоро за тяхно ограничение. Опитът, също така предполага, че мрежите с радиална базова функция не са склонни да екстраполират отвъд известните данни. Отговорът им бързо пада към нула ако се използват данни, намиращи се далече от данните използвани за обучението им. Често оптимизирането на изходния слой на

мрежите с радиална базова функция може да доведе до определено ниво на повлияване (пристрастност) с очакване, че резултатът ще бъде приблизително равен на средното ниво на продуцирания неоптимизиран резултат от изходния слой, така че всъщност екстраполирания резултат представлява наблюдаваната средна стойност, което на практика е едно разумно предположение.

За разлика от мрежите с радиална базова функция, многослойния перцептрон става по-сигурен в резултатите си, когато се използват далечни данни. Дали това може да се счете за предимство или недостатък зависи до голяма степен от приложението, но като цяло екстраполацията на мултислоевия перцептрон се счита за слаба точка (екстраполация далеч от данните за обучението обикновено се счита за опасна и неоправдана).

Мрежите с радиална базова функция, също така са по-чувствителни към мащаба на входящите данни и имат по-големи затруднения, ако броят на входните единици е голям. Един от аспектите на т. нар. „проклятие на измерението“ се изразява в това, че при увеличаване на броя на предсказателните единици (заради увеличаването на броя на входовете) се увеличава и дисперсията. Колкото по-висока е стойността на дисперсията, толкова по-трудно става за предсказващия алгоритъм да се представя добре, когато мрежата се захранва с нови данни.

Както бе споменато по-рано, обучението на мрежите с радиална базова функция се извършва на отделни етапи. Първо, центровете и отклоненията на радиалните единици трябва да бъдат определени, след което линейният изходен слой се оптимизира. Центровете трябва да бъдат определени по такъв начин, че да отразяват естественото групиране на данните. Двата най-често срещани методи са:

1. Избирателно формиране на подмножества данни (Sub-sampling). Случайно избраните точки за обучение се копират в радиалните единици. Тъй като те са избрани на случаен принцип, те ще представляват разпределение на данните за обучението в статистически смисъл. Все пак, ако броят на радиалните единици не е голям, радиалните единици могат да се представят неуспешно [126].

2. Алгоритъм на k -средните. Този алгоритъм [121] се опитва да избере оптимален набор от точки, които се намират в центроидите на групи от данни за обучение. При дадени K радиални единици, той настройва позициите на центровете така, че:

- Всяко място за обучение принадлежи към клъстерния център и е по-близо до този център, отколкото до всеки друг център;
- Всеки клъстер-център е центърът на точките за обучение, които принадлежат на него.

След като бъдат зададени центровете, се задават и отклоненията. Размерът на отклоненията (известен също като фактор на изглаждане) определя колко изпъкнала е формата на Гаусовите функции. Ако Гаусовите функции са твърде заострени, то мрежата не би могла да интерполира между известните ѝ точки, като по този начин тя би загубила способността си да обобщава. Ако Гаусовите функции са много широки, мрежата би загубила финните подробности. Това всъщност е друга проява на за прекомерно обучение на невронни мрежи. Отклоненията, обикновено трябва да бъдат избрани така, че гаусовите функции да се припокриват с няколко близки центъра. Наличните методи за това са:

- Изрично. За този метод е необходимо да се избере самото отклонение.
- Изотропно. Отклонението (еднакво за всички единици) се избира евристично, за да отрази броя на центровете и обема на пространството, което заемат (Хайкин, 1994).

- K - най-близък съсед. Отклонението на всяка единица е индивидуално зададено на средното разстояние до нейните k - най-близки съседи (Бишъп, 1995). Следователно, отклоненията са по-малки в плътно запълнените пространства, като по този начин запазват детайлите, и по-големи в малко наситените пространства като биват интерполирани, където е необходимо.

След като бъдат зададени центровете и отклоненията, изходният слой може да бъде оптимизиран с помощта на стандартната техника за линейна оптимизация, като например алгоритъма за псевдо-инвертиране.

Само че, мрежите с радиална базова функция, както е описано по-горе страдат от същите проблеми, като тези на мултислоевите перцептрони ако се използват за класификация - изходът на мрежата е мярка за разстояние от хипер равнина за вземане на решение, а не вероятностно ниво на доверие. Поради тази причина мрежите с радиална базова функция могат да бъдат модифицирани, като се включи изходен слой с логистични или softmax (нормализирани експоненциални) изходи, които са способни да оценяват вероятностите. По този начин се губи предимството на бързата линейна оптимизация на изходния слой, но въпреки това нелинейният изходен слой продължава да притежава сравнително добра повърхност на грешката и може да бъде оптимизиран доста бързо, използвайки бърз итеративен алгоритъм като конюгирано градиентно спускане.

Отношението на входния спрямо изходния слой на изкуствена невронна мрежа с радиална базова функция е дефинирана по следния начин:

$$y(i) = \sum_{j=1}^K w_j(n) \exp\left(-\frac{1}{2\sigma^2(n)} \|\mathbf{x}(i) - \boldsymbol{\mu}_j(n)\|^2\right), \quad i = 1, 2, \dots, n \quad (35)$$

Където: $\mu_j(n)$ е центъра на j -тия Гаусов елемент, измерителя за ширината $\sigma(n)$ е еднакъв за всички K елементи и $w_j(n)$ е линейно тегло на j -тия елемент; всичките параметри са измерени в момент от времето n . Функцията, използвана за обучението на мрежата се дефинира по следния начин:

$$\mathcal{E} = \frac{1}{2} \sum_{i=1}^n e^2(i) \quad (36)$$

където:

$$e(i) = d(i) - y(i) \quad (37)$$

Това е изпъкнала функция на линейните тегла в изходния слой, но не изпъкнала по отношение на центровете и ширината на Гаусовите единици.

Невронни мрежи с радиална базова функция също могат да бъдат хибридизирани по няколко начина. Радиалният слой (скритият слой) може да бъде обучен с помощта на

алгоритмите за обучение Kohonen и Learned Vector Quantization [127], които са алтернативни методи за определяне на центровете, които да отразяват разпространението на данните, а изходният слой (линеен или не) може да бъде обучен, като се използва, кой да е от итеративните точкови алгоритми на разположение в софтуерния продукт STATISTICA невронни мрежи [128].

3.2.5.2 Невронните мрежи с обща регресия

Невронните мрежи с обща регресия представляват базирани на памет невронни мрежи, които предлагат оценка на непрекъснати променливи и клонят към основната (линейна или нелинейна) регресионна повърхност. Те са представяни като разновидност на мрежите с радиална базова функция. Предложени от Д. Спач [129], те са обучаващ алгоритъм с еднократно преминаване на информацията за обучение през него, притежаващ високо паралелна структура. Този тип невронни мрежи са способни да осигурят гладък преход от едно наблюдение към друго дори при непълни данни в многоизмерно пространство за измерване. Алгоритмичната форма може да се използва за всеки проблем с регресията, при който предположението за линейност не е оправдано.

Сред най-важните предимства на невронните мрежи с обща регресия са бързото им обучение и бързата конвергенция (приближаване) до оптималната повърхност на регресията при голямо увеличение на броя на образците. Те предлагат особено предимство при непълни данни и в среда в реално време, защото повърхността на регресията бива дефинирана на момента и навсякъде, дори и при едни образец. Оценката на един образец е че Y ще бъде същия като наблюдаваната стойност, независимо от входящия вектор X . Втори образец би разделил пространството на висока и ниска половина с плавен преход помежду им. Повърхността започва да става постепенно по сложна след добавянето на всеки нов образец.

Основен недостатък на тази техника е количеството пресмятания, необходимо на обучената система да прогнозира нов изходящ вектор. С напредъка в областта на изчислителните технологии този недостатък постепенно е загубил важност.

Математически представянето и схематичната форма на мрежите с обща регресия е показано отдолу и на Фигура 17:

$$\hat{Y}(X) = \frac{\sum_{i=1}^m A^i \exp \left(-\frac{D_i^2}{2\sigma^2} \right)}{\sum_{i=1}^m B_i \exp \left(-\frac{D_i^2}{2\sigma^2} \right)} \quad (38)$$

Увеличена при всяко обучение Y^j за клъстер i


$$\begin{cases} A^i(k) = A^i(k-1) + Y^j \\ B^i(k) = B^i(k-1) + 1 \end{cases} \quad (39)$$

Където: m е броя на клъстерите

$A^i(k)$ и $B^i(k)$ – са стойностите на коефициентите на клъстери i след k наблюдения

$A^i(k)$ е сумата на Y стойности
 $B^i(k)$ е броя на шаблоните назначени за клъстер i
 σ е вероятност за ширина

$$\hat{Y}(X) = \frac{\sum_{i=1}^m A^i \exp\left(-\frac{C_i}{\sigma}\right)}{\sum_{i=1}^m B^i \exp\left(-\frac{C_i}{\sigma}\right)}. \quad (40)$$



Фигура 17: Изкуствена невронна мрежа с обща регресия

Изкуствената невронна мрежа с обща регресия изпълнява регресия, при която целевата променлива е непрекъсната, която извършва класификация, при която целевата променлива е категорична. Основните предимства пред многослойните перцептрони са:

- Времето за обучението на невронна мрежа с обща регресия е много по-малко, отколкото това за обучаване на многослоен перцептрон;
- Изкуствените невронни мрежи с обща регресия изпълнява често пъти са по-точни от многослойните перцептрони;
- Изкуствените невронни мрежи с обща регресия са сравнително нечувствителни към външни стойности (диви точки);
- Изкуствените невронни мрежи с обща регресия генерират точни прогнозиранни вероятности за целева вероятност.

Сред недостатъците на изкуствените невронни мрежи с обща регресия са:

- Изкуствените невронни мрежи с обща регресия са по-бавни от многослойните перцептрони при класифицирането на нови случаи;
- Изкуствените невронни мрежи с обща регресия изискват повече пространство за съхранение на модела.

При изкуствените невронни мрежи с обща регресия се наблюдават поне три слоя: входни, радиални и изходни слоеве. Радиалните единици се копират директно от данните за обучение, по един за всеки случай. Всяка една от радиалните единици моделира Гаусова функция, центрирана в конкретния случай на обучение. Налице е по един изходен елемент за всеки клас, като всеки е свързан с всички радиални модули, принадлежащи към неговия клас, с нула на брой връзки от всички останали радиални единици. Следователно изходните единици просто добавят отговорите на единиците, принадлежащи към собствения им клас. Резултатите са пропорционални на прогнозите на базата на ядрото на p.d.f.s на различните класове и чрез нормализиране на тези стойности до сума от [1;0], се продуцират оценки за вероятност на класа.

Базовата изкуствените невронни мрежи с обща регресия може да бъде модифицирана по два начина:

- При първия и основен подход се предполага, че пропорционалното представяне на класовете в данните за обучение съвпада с действителното представителство на популацията, която се моделира (т.нар. "Предварителни вероятности"). Ако предварителната вероятност е различна от нивото на репрезентиране в случаите на обучение, оценката на мрежата ще бъде невалидна. За да се компенсира това, могат да се дадат предварителни вероятности (ако са известни) и теглата на класовете да се коригират така, че да компенсират;
- При втория, всяка мрежа, която прави оценки въз основа на шумна функция, неизбежно ще доведе до някои неправилни класификации. Въпреки това, някои форми на неправилна класификация могат да се разглеждат като по-скъпи грешки от други. При изкуствените невронни мрежи с обща регресия в използвания софтуерен продукт може да бъде посочен четвърти слой, който включва матрица на загубите. Това се умножава по оценките на вероятностите в третия слой и се избира класа с най-ниска прогнозна стойност.

Единственият контролен фактор, който трябва да бъде избран при обучение на мрежи с обща регресия, е факторът на изглаждане (т.е. радиалното отклонение на Гаусовите функции). Както при мрежите с радиални базови функции, този фактор трябва да бъде избран така, че да причини разумно припокриване - твърде малки отклонения предизвикват много осезаемо приближаване, което не може да обобщава, докато твърде големите отклонения изглаждат детайлите. Подходящата цифра може лесно да бъде избрана чрез експеримент, като се избере число, което води до ниска

грешка при подбора, и за щастие мрежите с обща регресия не са прекалено чувствителни към точния избор на фактор за изглаждане.

Най-големите предимства на мрежите с обща регресия са фактът, че резултатът е вероятностен, което прави интерпретацията на изхода лесна и скоростта на обучение. Обучението на вероятностните невронни мрежи всъщност се състои главно в копиране на случаи на обучение в мрежата, като по този начин резултатът е възможно най-близко до моментното състояние.

Най-големият недостатък е размерът на мрежата - вероятностната невронна мрежа, всъщност съдържа целия набор от курсове за обучение и следователно заема много пространство и е бавна при продуциране на резултати.

Изкуствената невронна мрежа с обща регресия са особено полезни при експерименти с прототипи, например, когато се решава кои входни параметри да се използват, тъй като краткото време за обучение позволява да се извърши голям брой тестове в кратък период от време. Софтуерния продукт използван за имплементирането им в експеримента използва невронни мрежа с обща регресия, заедно с вероятностни невронни мрежи в алгоритмите за избор на функции, които автоматично търсят полезни входове.

3.3 Формулиране на второто изследване

В тази част на дисертацията ще бъдат анализирани три различни вида невронни мрежи и тяхната способност да прогнозират на база на времеви серии финансова информация от борсовия пазар на акции в България. Два от основните индекси на БФБ – София ще бъдат обект на интерес, използвайки многослоен перцептрон, обучен посредством алгоритъма с обратно разпространение на грешката и този с конюгирано градиентно спускане, изкуствени невронни мрежи с радиална базова функция и изкуствени невронни мрежи с обща регресия.

Контролирано обучение ще бъде приложено за подготовката на моделите за задачата, като то е най-популярната форма, използвана при изкуствени невронни мрежи. Накратко, този процес включва промяна на синаптичните тегла на невронната мрежа чрез прилагане на набор от примери за обучение или примери за задачи. Всеки пример се състои от уникален входен сигнал и съответстващ желан (целеви) отговор. На мрежата се представя пример, избран на случаен принцип от множеството, а синаптичните тегла на мрежата се модифицират, за да се сведе до минимум разликата между желания отговор и действителният отговор на мрежата, произведен от входния сигнал в съответствие с подходящ статистически критерий. По този начин мрежата се учи от примерите, като конструира входно-изходно картографиране на съществуващия проблем.

Както вече бе обяснено в предходния експеримент, българският фондов пазар е характерен с ниската си ликвидност и висока волатилност. Все пак компаниите, търгувани на него представляват широк кръг от икономиката на страната от сектора на индустриално производство, през този на недвижимото имущество до фармацевтичния сектори и месните банкови институции. Най-представителен за пазара е индексът Sofix, базиран на пазарната капитализация на петнайсетте компании, включени в него и преизчислен на база техния т.нар. free float или свободно търгувани акции. Другия индекс, който ще бъде разгледан в тази част е BG40. Той е базиран на представянето на цените на емисиите и обхваща 40 емисии обикновени акции на компаниите с най-голям брой сделки и най-висока средна стойност на дневния оборот през последните 6 месеца, като и двата критерия имат еднаква тежест. Освен общите изисквания емисиите,

включени в изчисляването на индекса, трябва да отговарят на следните допълнителни изисквания:


- Да бъдат допуснати до търговия на основния пазар на Българска фондова борса;
- Да бъдат търгувани на пазар, организиран от борсата, поне 3 (три) месеца преди въвеждането им в портфейла BG 40. При условие, че дадена емисия е прехвърлена за търговия от един пазарен сегмент на друг, датата на първото котиране на емисията се приема за първа дата на търгуване.

За жалост, считано от края на 2013 година БФБ София АД спря да изчислява стойността на индексът BG40, поради прекалено голямото влияние на една конкретна емисия акции в него, която заради единичната си цена по онова време, в размер на 1 500 лв е отговорна за 75% от представянето на индекса. Макар това да изглежда не особено логична формулировка за представителен индекс, някои от най-добре познатите ни индекси на развити пазари, като щатския Dow Jones IA и японския Nikkei 225 имат подобна структура.

Обект на експериментът отново ще бъде прогнозирането на стойностите на двата индекса в бъдещ момент, на база на предишна информация. Подробности за това ще бъдат изложени в следващите редове, като започнем с избраната база данни, на базата на които да бъде проведено изследването.

3.3.1 Избор на данни

Данните за експеримента са от официалния сайт на БФБ – София АД, съставени от ценова информация на дневна база за двата индекса периода от 04.01.2010 г. до 28.02.2013 г. и по-точно: стойност на затваряне, стойност на отваряне, най-висока стойност за деня и най-ниска стойност за деня. На база на проведени предишни изследвания от множество изследователи, както и опита от предходния експеримент бе взето решение за по-различно разпределяне на данните в трите подмножества, а именно – за обучение, за изпитване и за валидиране. Това бе направено, като за обучението бяха определени 70% от данните, частта за изпитване – 15% и тази за валидиране, отново 15%. Това се обуславя най-вече от резултатите на многослойния перцептрон в прогнозирането на индекса Sofix от по рано и желанието на автора да се правят по-малко предварителна обработка на данните. При голяма част от авторите на разгледаните статии, подхода към разпределението на данните е подобен. Освен това, не бяха забелязани признаци на прекомерно обучение на мрежите, което да налага ограничаване на размера на данните. Профилът на самите данни за стойностите на индекса Sofix вече беше разгледан. Този на данните за индекса BG40 обаче е малко по-различен. При него, в началото на периода се наблюдава консолидация, следвана от низходящ тренд и спад от 13%, след това сериозно нарастване от над 23%, нов спад от приблизително същият магнитуд и накрая продължителен възходящ тренд водещ до нарастване от 28% на стойността на индекса. За разглеждания период индексът има най-висока стойност от 135.64 и най-ниска стойност равна на 102.51. Графика на движението на индекса през разглеждания период е показана на Фигура 18.



Фигура 18: Графика на стойността на индекса BG40

3.3.2 Прогнозиране на индексите Sofix и BG40 с трите избрани модела

Трите вида невронни мрежи, изпробвани в това начинание са многослойния перцептрон, обучен с алгоритъма за обратно разпространение и конюгирано градиентно спускане, за когото вече бе писано в подробности в предходни точки. Другите две архитектури – невронната мрежа с радиална базова функция и невронната мрежа с обща регресия също бяха представени подробно. Докато първата е много широко разпространена и масово използвана, другите две притежават някои предимства, сред които опростена топология, по-голяма бързина на обучение и избягване на локалните минимума при обучение, които биха могли да ги направят по-успешни в задачата за прогнозиране. Наред с тези предимства, разбирасе алтернативните модели притежават и някои недостатъци, като по-големите изисквания за съхранение на информацията и др

В началото на този експеримент, бе решено да не извършва никаква дообработка на първоначално генерираните бази данни за Sofix и BG40, поради факта, че първите резултати от трите типа мрежи не показаха подобрене след превръщането на цифровите стойности на индексите в ежедневни промени. Избрания критерии за оценка на представянето на мрежите отново е грешката на мрежата при подмножествата, използвани по време на обучението - Средно квадратичната грешка. В математиката, терминът се обяснява, като статистическа мярка за големината на променлива величина. Той е особен полезен, когато величините са положителни и отрицателни, например при синусоидално разпределение на стойностите. Чрез него се определя основното понятие в теорията на вероятностите и математическата статистика – дисперсията (квадратният корен от която се нарича средно квадратично отклонение). Средноквадратична стойност на сбор от величини (или непрекъсната функция), тя е квадратен корен от средно аритметичното на квадратите на оригиналните стойности.

Многослойния перцептрон отново бе обучаван с алгоритмите обратно разпространение и конюгирано градиентно спускане, докато при другите две мрежови архитектури бе направено друго. Мрежите с радиална базова функция бяха обучени на база на алгоритмите k – средство (K-Means), k – най-близък съсед (K-Nearest Neighbor) и псевдо-инвертиране (Pseudo-inverse). Изкуствените невронни мрежи с обща регресия бяха обучени с алгоритъм за подбор на подмножества (Subsampling algorithm).

Резултатите от прогнозирането на индекса Sofix са представени в Таблица 8 отдолу.

	Neural network name	Training algorithm	Inputs	Hidden (1)	Hidden (2)	Test Error
1	Multilayer perceptron 1	Back-propagation, Conjugate gradient descent	1	3	0	0.023607
2	Multilayer perceptron 2	Back-propagation, Conjugate gradient descent	2	5	0	0.024466
3	Radial Basis Function NN 1	K-Means, K-Nearest Neighbor, Pseudo-inverse	1	42	0	0.001892
4	Radial Basis Function NN 2	K-Means, K-Nearest Neighbor, Pseudo-inverse	4	42	0	0.002034
5	General regression neural network 1	Subsampling algorithm	1	533	2	0.000832
6	General regression neural network 2	Subsampling algorithm	2	533	2	0.000741

Таблица 8: Прогнозиране на индекс Sofix


Както се вижда в таблицата с резултатите от теста, най-добър резултат, изразен като най-малка грешка на валидационните данни (Test Error) бе постигнат от невронните мрежи с обща регресия. Най-успешната мрежа е съставена от 2 елемента във входящия слой, 553 елемента в първия скрит слой, 2 елемента във втория скрит слой и един елемент в изходящия слой, отговарящ на търсената променлива. Генерираната грешка от по-добре представилата се мрежата бе 0.000741, а за втората 0.000832, като и двете са обучавани на база алгоритъм за подбор на подмножества (Subsampling algorithm).

Изкуствените невронни мрежи с радиална базова функция, показват постоянни и добри резултати, като двата най-добре представили се модела, показват грешка от съответно 0.001892 и 0.002034. Структурирани с по 1 и 4 елемента във входящия слой, и двете имат по 42 елемента в скрития слой и един изходен елемент, отговарящ на търсената променлива, като и двата са обучени с помощта на алгоритмите k – средство (K-Means), k – най-близък съсед (K-Nearest Neighbor) и псевдо-инвертиране (Pseudo-inverse). Алгоритъмът K-Means се опитва да избере оптимален набор от точки, които се намират в центровете на групи от данни за обучение. При дадени K радиални единици, той настройва позициите на центровете така, че всяка точка на обучение да принадлежи към клъстерния център и е по-близо до този център отколкото до всеки друг център, а всеки клъстер център е центърът на точките за обучение, които му принадлежат. След като бъдат зададени центровете, се задават отклоненията. Размерът на отклонението, известен също като фактор на изглаждане определя колко са изпъкнали Гаусовите

функции. При K-Nearest Neighbor всяко отклонение на единицата е индивидуално зададено на средно разстояние до K-Nearest Neighbor [121]. Следователно, отклоненията са по-малки в плътно запълнените пространства, запазвайки детайлите и по-високи в рядко запълнените пространства (като интерполират, където е необходимо). След като са настроени центровете и отклоненията, изходният слой се оптимизира, като се използва стандартната техника за линейна оптимизация - алгоритъмът за псевдо интервал (разлагане в сингулярна стойност) the pseudo-inverse (singular value decomposition) algorithm[24].

Мрежите от типа Многослоен перцептрон се оказват най-лошото представилите се от трите модела. Резултатите на двата най-добри техни представители са съответно 0.023607 и 0.024466, продуцирани от мрежи, изградени от три слоя, притежаващи 1 вход, 3 елемента в скрития слой за първия и 5 елемента в скрития слой за втория, както и един елемент в изходния слой, отговарящ на търсената променлива и за двата модела. Обучени с 100 епохи обратно разпространение и 34 епохи конюгирано градиентно спускане за първата и 100 епохи обратно разпространение и 34 епохи конюгирано градиентно спускане за втората, те се представят значително по-лошо.

Графично, прогнозите на шесте изброени в Таблица 8 мрежи за избран период е показана на Фигура 19



Фигура 19: Графика на прогнозите за Sofix на изкуствените невронни мрежи

На този етап, няма как да не бъдат отчетени някои изненадващи факти. На първо място е добрите резултати, които показват, както невронните мрежи с обща регресия, така и тези с радиална базова функция. Те изглежда се справят много по-добре в моделирането на данните на входовете си, като успяват да продуцират еднакво добри резултати резултати изолирайки различен брой входящи параметри. Например втората най-добра мрежа с обща регресия използва два неврона във входящия си слой отговарящи съответно за целевата променлива – последна стойност на индекса за деня (стойност на затваряне) и най-ниската стойност за деня, докато втората най-добра мрежа с радиална базова функция използва всичките 4 входни параметри (освен горните две и стойност на отваряне и най-ниска стойност за деня).

Макар резултатите на многослойния перцептрон да са по-добри от постигнатите по време на провеждането на първия експеримент, те остават в пъти по-лоши от тези на описаните по горе модели. Тази тенденция е видима не само при валидиращите данни, а на база данните за грешката по време на обучението и при изпитването на мрежата. В Таблица 9 са представени данните за грешките на шестте модела по време на обучението и при изпитващия сет от данни.

	Neural network name	Training algorithm	Train Error	Select Error
1	Multilayer perceptron 1	back-propagation, conjugate gradient descent	0.020964	0.023328
2	Multilayer perceptron 2	back-propagation, conjugate gradient descent	0.020729	0.023204
3	Radial Basis Function NN 1	K-Means, K-Nearest Neighbor, Pseudo-inverse	0.001732	0.002120
4	Radial Basis Function NN 2	K-Means, K-Nearest Neighbor, Pseudo-inverse	0.001937	0.002068
5	General regression neural network 1	Subsampling algorithm	0.000962	0.000877
6	General regression neural network 2	Subsampling algorithm	0.000785	0.000697

Таблица 9: Грешка при обучение и изпитване на невронните мрежи за Sofix

При прогнозирането на индекса BG40, ситуацията не бе много по-различна. Изкуствените невронни мрежи с обща регресия отново бяха най-продуктивни и постигнаха най-ниски стойности при валидиращия сет. Най-ниската стойност за грешката бе 0.004963, постигната от мрежа състояща се от 2 елемента във входящия слой, 550 елемента в първия скрит слой, 2 елемента във втория скрит слой и един елемент в изходящия слой, отговарящ на прогнозираната променлива. Този път използваните параметри на входа са последната стойност на индекса за деня и неговата най-висока стойност за деня. За разлика от преди втората най-добра мрежа от този тип използва един елемент във входящия слой, 550 елемента в първия скрит, 2 елемента във втория скрит и един елемент във изходящия слой, отговарящ на прогнозираната променлива. Постигнатите резултати по отношение стойността на грешките при нея е 0.005467. И двете мрежи са обучавани на база алгоритъм за подбор на под-множества (Subsampling algorithm).

Втори резултат дава мрежовата архитектура с радиална базова функция с 2 елемента във входящия слой, съответстващи на параметрите последна стойност на индекса за деня и най-висока стойност на индекса за деня, 30 елемента във скрития слой и един елемент във изходния. Подобна структура притежава и втората най-добра мрежа от този вид, но тя използва всичките 4 параметъра за да прави своите прогнози. Постигнатите резултати по отношение стойността на грешките са съответно 0.014879 за първата и 0.0155 за втората. И двете мрежи са обучени с помощта на алгоритмите k – средство (K-Means), k – най-близък съсед (K-Nearest Neighbor) и псевдо-инвертиране (Pseudo-inverse).

Отново, третото място се заема от многослойните перцептрони, които успяват да скъсат дистанцията между представянето си и това на следващия модел значително,


утилизирайки по един елемент във входящия слой, един за по-добрата мрежа и респективно два елемента в скрития слой на втората мрежа и един елемент в изходящия слой. Постигнатите резултати по отношение стойността на грешките са съответно 0.032738 за първата и 0.032934 за втората. И в този случай, обучението на база 100 епохи обратно разпространение и 28 епохи конюгирано градиентно спускане за първата и 100 епохи обратно разпространение и 18 епохи конюгирано градиентно спускане за втората се оказва недостатъчно добро за да бъдат тези модели конкурентни на останалите.

Таблица с обобщената информация за резултатите на трите мрежови архитектури, използвани за прогнозирането на BG40 е показана на Фигура 10.

	Neural network name	Training algorithm	Inputs	Hidden (1)	Hidden (2)	Test Error
1	Multilayer perceptron 1	Back-propagation, Conjugate gradient descent	1	1	0	0.032738
2	Multilayer perceptron 2	Back-propagation, Conjugate gradient descent	1	2	0	0.032934
3	Radial Basis Function NN 1	K-Means, K-Nearest Neighbor, Pseudo-inverse	2	30	0	0.014879
4	Radial Basis Function NN 2	K-Means, K-Nearest Neighbor, Pseudo-inverse	4	30	0	0.015500
5	General regression neural network 1	Subsampling algorithm	1	550	2	0.005467
6	General regression neural network 2	Subsampling algorithm	2	550	2	0.004963

Таблица 10: Прогнозиране на индекс BG40

Графично, прогнозите на шесте изброени в Таблица 10 мрежи за избран период е показана на Фигура 20



Фигура 20: Графика на прогнозите за BG40 на изкуствените невронни мрежи

При задачата за прогнозиране на BG40 отново се потвърждават добрите резултати, които показват невронните мрежи с обща регресия. Като цяло, грешките и при трите разновидности растат спрямо тези продуцирани при прогнозирането на Sofix, нещо което вероятно се дължи и на по-голямата волатилност на индекса и на някои други фактори свързани със селекцията на входните данни. Големи размествания в класирането на моделите спрямо предходния експеримент не се наблюдава. Донякъде, за неочаквано може да се счете използването на 2 параметъра на входа от най-сполучливия модел, което се случва за първи път, но и при предходния случай, разликата между, този залагащ само на търсената променлива и втория най-успешен бе твърде малка.

Резултатите на многослойния перцептрон са по-лоши от постигнатите по време на провеждането на теста върху Sofix, но това, както вече бе споменато е общата тенденция. При тях се наблюдава тенденция на доближаване до резултатите на мрежите с радиална базова функция, което може да се приеме като позитивен фактор. Резултатите на трите модела по отношение на грешката по време на обучението и тази при изпитващия сет запазват тенденциите наложени от базовото оценяване. Таблица 11 са представени данните за грешките на шестте модела по време на обучението и при изпитващия сет от данни.

	Neural network name	Training algorithm	Train Error	Select Error
1	Multilayer perceptron 1	back-propagation, conjugate gradient descent	0.030735	0.030305
2	Multilayer perceptron 2	back-propagation, conjugate gradient descent	0.031003	0.030096
3	Radial Basis Function NN 1	K-Means, K-Nearest Neighbor, Pseudo- inverse	0.013824	0.014520
4	Radial Basis Function NN 2	K-Means, K-Nearest Neighbor, Pseudo- inverse	0.013939	0.014501
5	General regression neural network 1	Subsampling algorithm	0.006539	0.006804
6	General regression neural network 2	Subsampling algorithm	0.005665	0.006288

Таблица 11: Грешка при обучение и изпитване на невронните мрежи за BG40

Резултатите от изследването на способностите за прогнозиране на трите вида невронни мрежи могат да се определят като полезни и до голяма степен изненадващи. Малко неочаквано, най-добре представилия се модел бяха невронните мрежи с обща регресия, при това с много по-ниски стойности на измерваната грешка, както при валидиращия набор, така и при данните за обучение и изпитване. Постоянството в резултатите им ги прави безапелационни победители в това своеобразно съревнование. По този начин, те потвърждават до голяма степен позитивните си атестации, отбелязани априори проведените на експерименти, като по-бързи и успешни, способни да се справят с данни съдържащи отклонения.

Много добро и постоянно представяне се отчита и за модела използващ радиална базова функция. Те показват успех при боравенето с повече от един входящ параметър за прогнозиране на целевата променлива, което ги отличава от останалите.

Многослойния перцептрон може да бъде определен като най-лошо представилата се мрежа в прогнозирането и на двата индекса, като не добрите ѝ резултати се потвърждават, както от размера на грашката по време на валидиращите данни, така и от този при обучението и изпитването му. Въпреки, че размерът на продуцираната от него грешка не е голям и абстрахирайки се от резултатите на другите модели, неговия може да бъде счетен за задоволителен, прогнозите му надеждни, гледайки нещата на релативна база не можем да бъдем доволни. Факт е, че при по-волатилните данни за индекса BG40 разликата от другите модели и по-конкретно от тези с радиална базова функция се стопява значително, но това не може да бъде причина за самодоволство.

На база на проведеното изследване на възможността за прогнозиране на индексите на българския фондов пазар с три от многобройните видове изкуствени невронни мрежи може да бъде направено заключението, че този клас модели от областта на изкуствения интелект може да се справи успешно със задачата да прогнозира бъдещи стойности свързани с финансови инструменти на база на времеви серии финансова информация. Веднага трябва да бъде направено уточнението, че това в никакъв случай не означава, че те са способни да осъществяват успешна търговия на капиталовите

пазари, още повече, че и проведените експерименти не предполагат такава възможност. За сметка на това, със сигурност те са способни да подпомогнат един по-комплексен модел насочен към действителна търговия на фондовия пазар, дори в условия като тези на българския пазар.

3.4 Хибриден модел от невронни мрежи и системи основани на правила за прогнозиране на капиталовия пазар: Индекс Sofix на БФБ – София

Капиталовият пазар в различните части на света е много различен поради особеностите на множеството изграждащи го елементи. В този труд вече беше описано в подробности колко големи са разликите между развитите пазари и не добре развитите такива. Това неминуемо води до също толкова големи разлики в техниките, които се прилагат на тези пазари, за да се придобие предимство пред останалите участници и разбира се, да се постигне печалба.

Докато на развитите пазари се прилагат множество различаващи се по сложност стратегии включително алгоритмични и високочестотни стратегии [13] за търговия, които позволяват на авторите им да имат преимущество по отношение на скорост на изпълнение на сделките и откриване на пазарни тенденции, подобен подход за търговия на БФБ – София е невъобразим. Тъй като България е подала заявление за присъединяване към Евророната и очаква приемане в ERM II (Европейски механизъм за обменни курсове) [130] през следващите години, ликвидността на пазара, броя и профила участниците и привлекателността на борсата могат да се променят към по-добро в бъдеще. Въпреки това, при добри познания за ликвидността и структурата на родния пазар и на техниките на изкуствения интелект може да бъде направен опит да се формулира модел, който да се възползва от определени фактори, за да даде така търсеното преимущество пред останалите участници на пазара. С прилагането на все повече регулации като Директива за пазарите на финансови инструменти (MiFID II) [16] за търговците на финансовите пазари е много важно техните търговски стратегии да бъдат съобразени с тях. В следващите редове ще бъде зададена рамката и градивната структура на такъв модел.

Използването на техники от инструментариума на Изкуствения интелект се предлага за постигането на тази цел, като със задачата за класиране на емисиите на база на информация от двата основни източника (бюлетина на БФБ за дневната търговия и бюлетина на Централен депозитар за фрий флоут и брой акционери) и набор от правила съставляващи правилата за определяне на индекса е натоварена система основана на правила, а със задачата за прогнозиране на динамични редове финансова информация ще се разчита на няколко вида невронни мрежи [131].

3.4.1 Дефиниране на задачата

БФБ София е относително млад пазар на финансови инструменти с традиционна организация на търговията и скромнен оборот в сравнение с повечето пазари от региона. Борсовият оператор, наред с организация на търговията и оповестяване на информация за сделки и емитенти е отговорен за изчисляването на няколко пазарни индекса, които както е общоприето, служат за своеобразен барометър за цялостното представяне на борсовия пазар в страната. Най-известния и представителен индекс на БФБ София е Sofix. Той е базиран на пазарната капитализация на включените в него емисии обикновени акции, коригирани с свободно търгуемия обем (Фрий флоут) на всяка от тях. Индексът покрива 15 броя акции, отговарящи на общите изисквания за избор на емисии, както и на допълнителни количествени изисквания. Емисиите, включена в изчисляването

на Sofix е необходимо да отговарят на показатели, сред които: изискване за минимално време през което са търгувани, минимална пазарна стойност на техния фрий-флоут, минимален броят акционери притежаващи емисията и наличен спред между цените „купува“ и „продава“. Индексът се ребалансира два пъти в годината, като тези стойности се вземат след края на търговските сесии на съответно на 1-ви Март и 1-ви Септември. Окончателния състав на индекса се определя след като всички емисии отговарящи на изискванията бъдат класирани съобразно 4 количествени показателя, като и четирите показателя са с равно тегло:

- най-голяма пазарна стойност на фрий-флоута;
- най-голям брой сделки за последния шестмесечен период;
- най-голяма медианна стойност на седмичния оборот за последния шестмесечен период;
- най-малка средно-аритметична стойност на спреда между цените „купува“ и „продава“

Считано от месец Септември 2016 г на БФБ - София се търгува българският борсово търгуван фонд, който следва представянето на основния борсов индекс Sofix – Expat Bulgaria SOFIX UCITS ETF, чийто активи към края на Август 2019 са малко под 25 млн. лв. Фонда е пасивно управляван и се придържа към метода на пълно физическо репликиране на индекса. Целта на фонда е да следва представянето на индекса, като реализира минимално отклонение от представянето му.

Освен това индексът Sofix служи за бенчмарк за малкото чуждестранни инвестиционни фондове с присъствие на нашия пазар, както и на множество портфейли на индивидуални инвеститори, поверени за доверително управление. Всичко това прави изключително важно неговия състав и съответно при ребалансирането му – кои компании остават в неговия състав, кои компании го напускат и кои се добавят към изчислението му. Според направено от автора проучване на изменението на цените на акциите за последните 5 ребаланса на Sofix, средната промяната в цените на отпадащите от изчислението му компании е в размер на -8.35% за период от един месец предхождащ крайната дата на вземания под внимание за определянето на състава времеви отрязък, а промяната в цените на добавените към изчислението му компании е в размер на +12.00% за период от един месец преди крайната дата на вземания под внимание за определянето му времеви отрязък.

Това наблюдение в комбинация с фактът, че компаниите отпадащи и добавяни към индекса са сред най-търгуваните на пазара представлява добра възможност за създаване на стратегия за търговия, която е базирана на отгатване на състава на индекса в аванс, преди останалите участници на пазара и реализиране на печалба чрез покупка на акциите на добавените към състава на индекса компании и/или продажба на акциите на отпадащите от индекса компании. Но как може да бъде постигнато това с достатъчен аванс преди конкурентите на пазара, че да бъде печеливша стратегия?

Авторът на този труд предлага създаването на хибриден модел на базата на техниките на Изкуствения интелект: базирани на правила системи и невронни мрежи, който да прогнозира състава на индекса Sofix преди това да бъде направено от останалите участници на пазара.

3.4.2 Представяне на източниците на информацията, захранващи моделът.

Информацията, с която е необходимо да се захрани модела е публично достъпна и се формира от дневния бюлетин, публикуван от БФБ – София [131], съдържащ цялата информация за дневната търговия на всички емисии ценни книжа, регистрирани за търговия, както и бюлетина за фрий флоута на търгуваните емисии, публикуван от Централен депозитар [132]. Данните за правилата за определяне на състава на индекса ще бъдат взети от правилата за изчисляване на индекси на БФБ – София.

137-23 07/2019 06:30:01 PM

Дневен Бюлетен

НА БЪЛГАРСКА ФОНДОВА БОРСА

Адрес: ул. Трънски 6, София, България
Телефон: (+359 2) 937 09 34
Факс: (+359 2) 937 09 46
E-mail: info@bse-bf.bg
Web Page: http://www.bse-bf.bg

Стойност на индексите на БФБ-София към края на търговския ден

SOPIX 579.150
BGEX40 114.560
BGEX40 TI 134.110
BGREIT 126.790
BGTR30 507.800

ПАЗАРИ АКЦИИ И ДРУГИ НЕДЪЛГОВИ ЦЕННИ КНИЖА

Код	Наименование	Вид	Валута	Курс/цена	Дата	Дел. кот. %	Кредит делта	Делени от капитала 23/07/2019				Налична цена към и налична цена "пазарът"				Обороти			Пазарен обем	Маржа изчисления	Клас	
								Цена				Средна		Западна		Обороти						
								Открито	Ниска	Ниска	Пром. %	Средна	Западна	от Дата	Пром.	Обор.	Куп.	Обор.				
0EA	Елени Агроиндустриал АД-София	1	BGN	10.6.2019	0.0582	4.97	9675	11.700	11.700	11.700	0.85	11.700	11.700	23.7.2019	11.800	38303	1.1600	250	Сегмент акции Standard		0	
0SP	Стефан АД-София	1	BGN	28.6.2019	1.4000	2.89	32	48.0000	48.4000	48.0000	-3.20	48.3500	48.4000	23.7.2019	50.000	68	48.0000	22	Сегмент акции Standard		0	
17EB	Нео Лондон Капитал АД-София	100	BGN										128.0000	128.0000	3.7.2019			128.0000	1	Сегмент акции Standard		0
1CD	ЧЕЗ Електро България АД-София	10	BGN										22000.0000	22000.0000	2.7.2019	1	1	1	Сегмент акции Standard		0	
1VX	Ветеринар Асес Монастирски АД-София	1	BGN										3.9000	3.9000	28.6.2019	50.0000	10	3.5000	200	Сегмент акции Standard		0
282N	БПД Индустриален фонд за недвижими имоти АД-СИЦ-Соф	1	BGN																Сегмент за борсово търгувани продукти		0	
2YH	ВФ Агратика АД-София	1	BGN																Сегмент акции Standard		0	
3CD	ЧЕЗ Разпределение България АД-София	1	BGN	4.7.2017	25.4000		20	234.0000	234.0000	234.0000	0.00	234.0000	234.0000	23.7.2019	234.0000	540	232.0000	8	Сегмент акции Standard		0	
3JR	Софияна АД-София	1	BGN	27.9.2018	0.0500		910	3.3000	3.3000	3.3000	-0.30	3.3000	3.3000	23.7.2019	3.3200	1000	3.2900	217	Сегмент акции Premium		0	
3NB	Нискоан АД-Долнопротурца	1	BGN	27.6.2018	0.2000								23.0267	23.0000	18.7.2019	25.9000	73	23.0000	32	Сегмент акции Standard		0
3NT	Св. Ст. Константин и Елена Холдинг АД-Варна	1	BGN										22.2000	22.2000	11.7.2019	22.0000	100	20.0000	50	Сегмент акции Standard		0
3TV	Топливо АД-София	1	BGN	8.6.2006	0.2500		650	2.8000	2.8000	2.8000	0.00	2.8000	2.8000	23.7.2019	3.1000	500	2.8000	2330	Сегмент акции Standard		0	
3ZL	Златни пазари АД-Варна	1	BGN										2.3675	2.7000	17.4.2019	2.4400	231	1.8000	500	Сегмент акции Standard		0
4CF	ТБ Централна кооперативна банка АД-София	1	BGN				64	1.4700	1.4700	1.4700	0.68	1.4700	1.4700	23.7.2019	1.5000	2000	1.4750	2000	Сегмент акции Premium		0	
4EN	Европолска България АД-София	1	BGN	11.7.2019	0.0125	0.63	305	2.0000	2.0000	2.0000	0.00	2.0000	2.0000	23.7.2019	2.0000	1295	1.8700	215	Сегмент акции Standard		0	
4F9	Фазарис АД-Силистра	1	BGN	27.6.2019	0.5000								21.0000	21.0000	19.7.2019	21.2000	75	19.3000	94	Сегмент акции Standard		0
4F9	Форомикс АД-Харжики	1	BGN										5.5000	5.5000	2.7.2019	5.7500	109	5.0000	5	Сегмент акции Standard		0
4NE	Холдингска компания и системи АД-Ямбол	1	BGN	27.5.2019	0.2600	5.31	1855	4.9000	4.9000	4.9000	-0.41	4.9000	4.9000	23.7.2019	4.9500	367	4.8300	490	Сегмент акции Standard		0	
4NE	Холдинг Сигма София АД-София	1	BGN										3.3733	3.3600	18.7.2019	3.5000	75	3.3600	75	Сегмент акции Standard		0
4ID	Индустриален Капитал Холдинг АД-София	1	BGN	26.6.2019	0.0735								2.2600	2.2600	18.7.2019	2.3800	350	2.2800	440	Сегмент акции Standard		0
4ID	Индустриален Холдинг България АД-София	1	BGN				242	1.0100	1.0100	1.0100	1.00	1.0100	1.0100	23.7.2019	1.0300	928	1.0100	591	Сегмент акции Standard		0	
4IN	Инвестор БГ АД-София	1	BGN										16.2000	16.2000	11.7.2019	30.0000	50	11.9000	94	Сегмент акции Standard		0
4KX	Хоразо-България АД-Струмица	1	BGN	28.5.2019	0.1900								6.8597	6.9000	22.7.2019	6.9500	300	6.7500	85	Сегмент акции Premium		0
4L4	Лавана АД-Шумен	1	BGN	14.6.2019	0.0300								3.8000	3.8000	8.7.2019	4.0000	1000	3.4000	500	Сегмент акции Standard		0
4O1	Продукция и добив на нефт и газ АД-София	1	BGN	11.7.2019	0.2300								6.9500	6.9500	17.7.2019	7.0000	485	6.5500	500	Сегмент акции Standard		0
4PZ	Юрий Татариан АД-Пловдив	1	BGN	7.7.2006	2.2500								10.0000	10.0000	22.7.2019	10.5000	137	9.8000	100	Сегмент акции Standard		0
5VE	Елени Илари АД-Пловдив	1	BGN	22.5.2019	0.0160	1.82	1300	0.9000	0.9000	0.8800	-5.38	0.8877	0.8800	23.7.2019	0.9350	2730	0.8600	3900	Сегмент акции Standard		0	
5TE	ЕДМЛА АД-Самуилов	1	BGN	29.5.2019	0.0942								2.7600	2.7600	10.7.2019	2.7000	525	2.4200	500	Сегмент акции Standard		0
5SE	Холмисаг България АД-София	1	BGN										42.6000	42.6000	12.7.2019	42.6000	14046	38.4000	60	Сегмент акции Standard		0
5AF	Фар АД-София	1	BGN										3.5000	3.5000	11.7.2019	4.0000	1000		Сегмент акции Standard		0	
5AX	Актив Прометис АД-СИЦ-Пловдив	9	BGN	17.5.2012	0.0050								6.6000	6.6000	11.7.2019	7.1500	200	6.6000	150	Сегмент за дружества със специални инвестиционни		0
5BD	Булевард инвестиментс АД-СИЦ-София	1	BGN	6.7.2016	0.0504								1.0700	1.0700	8.7.2019	1.0900	925	0.9500	2	Сегмент за дружества със специални инвестиционни		0
5BN	ТБ България-Американска Кредитна Банка АД-София	1	BGN	30.4.2008	1.5000								6.4500	6.4500	15.7.2019	6.6000	4433	6.4500	395	Сегмент акции Standard		0
5BP	ВинБора АД-София	1	BGN										0.2600	0.2600	18.7.2019	0.2700	4000	0.2420	4600	Сегмент акции Standard		0
5ER	Пиреллохотел Витерско речено плаване АД-Руса	1	BGN	12.6.2006	0.9596								0.7500	0.7500	16.7.2019	0.7400	1000	0.6400	2800	Сегмент акции Standard		0
5BU	Фонд за недвижими имоти България АД-СИЦ-София	1	BGN	16.7.2019	0.0996	4.93	1656	2.0200	2.0200	2.0200	0.00	2.0200	2.0200	23.7.2019	2.0200	5640	2.0000	4500	Сегмент за дружества със специални инвестиционни		0	
5CP	ТБ Тасиса Банк АД-София	1	BGN										2.6645	2.7000	12.7.2019	2.9000	885	2.4800	200	Сегмент акции Standard		0
5DOV	Дюверия Обществени Холдинг АД-София	1	BGN	13.7.2006	0.0538		399	3.2000	3.3000	3.2000	0.63	3.2634	3.2200	23.7.2019	3.3000	2871	3.2200	880	Сегмент акции Standard		0	
5EO	Европа АД-Европа	1	BGN	11.7.2008	0.2124								5.5500	5.5500	2.7.2019	5.7000	1024	4.7000	200	Сегмент акции Standard		0
5EK	Експлуатив Прометис АД-СИЦ-София	1	BGN										1.1359	1.3000	28.6.2019	1.2900	1500	0.7550	1000	Сегмент за дружества със специални инвестиционни		0
5F4	ТБ Тария Инвестиционна Банка АД-София	1	BGN				5302	3.0000	3.0000	2.9800	-0.66	2.9943	3.0000	23.7.2019	3.0000	4200	2.9800	1000	Сегмент акции Premium		0	
5H4	Болкан екс Спй Прометис АД-СИЦ-Варна	1	BGN	13.7.2011	0.0011								16.6000	16.6000	10.7.2019	16.6000	10	15.0000	7	Сегмент за дружества със специални инвестиционни		0
5MB	Монбат АД-София	1	BGN	11.7.2019	0.1026	1.57	6672	6.6000	6.6000	6.5500	-1.50	6.5340	6.5500	23.7.2019	6.8000	450	6.6000	40	Сегмент акции Premium		0	

Фигура 21: Бюлетин на БФБ – София с данните за търговията

**ЦЕНТРАЛЕН ДЕПОЗИТАР АД**

Фрий флоут на публичните дружества регистрирани в Централен Депозитар към дата: 30-08-2019

Емитент	Емисия	Общ Брой Фи	Фрий Флоут	Брой Акционери
235 ХОЛДИНГС АД	BG1100017174	5109000	3521678	50
"АГРИЯ ГРУП ХОЛДИНГ" АД	BG1100085072	6800000	1213783	331
АГРО ФИНАНС АДСИЦ	BG1100039061	32219708	38524	25
АГРОЕНЕРДЖИ АДСИЦ	BG1100031084	18500000	25400	4
"АГРОЕНЕРДЖИ ИНВЕСТ" АДСИЦ	BG1100025080	27961916	100	2
АДВАНС ЕКУИТИ ХОЛДИНГ АД	BG1100033064	35945592	24123794	166
"АДВАНС ТЕРАФОНД" АДСИЦ	BG1100025052	85110091	49881546	1854
"АКТИВ ПРОПЪРТИС" АДСИЦ	BG1100003059	2192011	1332423	182
"АКУМПЛАСТ" АД	BG11AKDOAT10	7233	1721	107
"АЛБЕНА" АД	BG11ALBAAT17	4273126	1307227	77725
АЛКОМЕТ АД	BG11ALSUAT14	17952959	1776504	2522
АЛТЕРКО АД	BG1100003166	15000000	2327260	253
"АЛТЕРОН" АДСИЦ	BG1100111076	605000	134081	14
АЛФА БЪЛГАРИЯ АД	BG1100038097	1181160	1	2
"АЛФА ПРОПЪРТИ 1" АДСИЦ	BG1100059069	650000	0	2
АРКО ТАУЪРС АДСИЦ	BG1100017075	682500	61434	9
"АРМЕЙСКИ ХОЛДИНГ" АД	BG1100009973	515838	489549	20408
АРОМА АД	BG1100087987	15491829	1703735	601
"АРОМА РИЪЛ ЕСТЕЙТ" АД	BG1100030110	3098360	310315	668
АРТАНЕС МАЙНИНГ ГРУП АД	BG1100005112	2000000	80392	12
"АСЕНОВА КРЕПОСТ" АД	BG11ASASBT10	4296006	1020690	9512
АТОМЕНЕРГОРЕМОНТ ЕАД	BG1100007159	15355140	3418243	35
БАЛКАНИКА ИМОТИ АДСИЦ	BG1100041083	650000	33305	7
"БАЛКАНКАР-ЗАРЯ" АД	BG11BARAAT13	2403956	268641	413
БГ АГРО АД	BG1100151072	40357440	6249967	70
"БИ ДЖИ АЙ ГРУП" АД	BG1100016077	6665000	1622995	38
БИАНОР ХОЛДИНГ АД	BG1100007076	675222	193213	99
БИЛБОРД АД	BG1100088076	15000000	3762532	508
БИОИАСИС АД	BG1100008082	1200000	36803	11
БОЛКАН ЕНД СИЙ ПРОПЪРТИС АДСИЦ	BG1100099065	6925156	3207587	49
БОЛКАН ПРОПЪРТИ ИНСТРУМЕНТС АДСИЦ	BG1100072070	65000	0	2
БПД Индустириален Фонд за Недвижими Имоти АДСИЦ	BG1100008157	2650000	15000	2
"БРАВО ПРОПЪРТИ ФОНД" АДСИЦ	BG1100016176	36700000	7638100	89
"БРЯСТ -Д" АД	BG11BRDOBT11	400000	12874	293
БУЛВЕСТА ХОЛДИНГ АД	BG1100008975	719703	331542	10782
БУЛГАР ЧЕХ ИНВЕСТ ХОЛДИНГ АД	BG1100053989	1191105	967535	6874
"БУЛГАРИ РЕЗЕРВ ПРОПЪРТИС" АДСИЦ	BG1100148072	650000	0	2
"БУЛГАРТАБАК-ХОЛДИНГ" АД	BG11BUSOGT14	7367222	142034	1417
БУЛГЕРИЪН ИНВЕСТМЪНТ ГРУП АДСИЦ	BG1100047056	650000	60277	23
БУЛЛЕНД ИНВЕСТМЪНТС АДСИЦ	BG1100067054	15008125	8960575	157
БЪЛГАРО АМЕРИКАНСКА КРЕДИТНА БАНКА - АД	BG1100098059	24691313	1248190	293
"БЪЛГАРСКА ЗАХАР" АД	BG11BADOAT11	718162	105775	2040
"БЪЛГАРСКА РОЗА - ПЛОВДИВ" АД	BG11B1PLAT15	211894	71966	1181
БЪЛГАРСКА РОЗА АД - КАРЛОВО	BG11BAKAAT18	5350980	962895	1646
БЪЛГАРСКА ФОНДОВА БОРСА АД	BG1100016978	6582860	3287860	457
БЪЛГАРСКА ХОЛДИНГОВА КОМПАНИЯ АД	BG1100001988	6583803	3970688	139926
БЪЛГАРСКИ ТРАНСПОРТЕН ХОЛДИНГ АД	BG1100020988	328523	169307	4512
"БЪЛГАРСКИ ФОНД ЗА ВЗЕМАНИЯ" АДСИЦ	BG1100001186	1500000	0	1
БЪЛГАРСКИ ФОНД ЗА ДЯЛОВО ИНВЕСТИРАНЕ АД	BG1100001129	8771006	3597055	27
ВАЛОР ПРОПЪРТИС АДСИЦ	BG1100013108	650000	91500	5

Фигура 22: Бюлетин на Централен депозитар за данните за фрий флоута и броя акционери на компаниите.

3.4.3 Използвани невронни мрежи и системи основани на правила.

Системата основана на правила използва правилата, като представяне на знания за знания, кодирани в системата [134]. Дефинициите на системи основани на правила почти изцяло зависят от експертни системи, които са система, имитираща разсъжденията на експерт – човек при решаване на проблем, който изисква наличието на задълбочени знания. Вместо да представя знанието по статичен начин, като съвкупност от неща, които са истинни, системата основана на правила представя знанието по отношение на набор от правила, който казва какво да правите или какво да бъде заключението в различни ситуации.

Системата основана на правила, е начин за кодиране на знанията на експерт - човек в относително тясна област в автоматизирана система. Системата основана на правила, може просто да бъде създадена, като се използва набор от твърдения и набор от правила, които определят как да се действа върху набора от твърдения. Правилата се изразяват като съвкупност от „Ако – То“ действия (по-известни като IF-THEN RULES или правила за продуктивната фаза) като например:

IF P THEN Q

което е еквивалентно на:

P»Q.

Системата основана на правила, се състои от набор от „Ако – То“ правила, набор от факти и интерпретиращ елемент, контролиращ прилагането на правилата, като се имат предвид фактите. Идеята на експертната система е да използва знанията от експертна система и да я кодира в набор от правила. Когато е изложена на същите данни, експертната система ще изпълнява (или се очаква да изпълнява) по подобен начин на експерта. Системите, базирани на правила, са много прости модели и могат да бъдат адаптирани и приложени за голям вид проблеми. Изискването е знанията за проблемната област да бъдат изразени под формата на правила „if-then“. Районът също не трябва да бъде толкова голям, тъй като голям брой правила могат да направят решаването на проблема (експертната система) неефективен.

Системата основана на правила, обикновено е изградена от няколко основни и прости елементи, които са:

1. Набор от факти. Тези факти всъщност са твърденията и би трябвало да са от значение за началното състояние на системата

2. Набор от правила. Те съдържат всички действия, които трябва да се предприемат в обхвата на проблем, като посочват как да действате върху набора от твърдения. Дадено правило свързва фактите в частта IF към някои действия в частта THEN. Системата трябва да съдържа само релевантни правила и да избягва нерелевантните, тъй като броят на правилата в системата ще повлияе на нейната ефективност.

3. Критерий за прекратяване. Това е условие, което определя дали е намерено решение или няма такова. Това е необходимо за прекратяване на някои базирани на правила системи, които в противен случай се оказват в капана на безкрайна примка.

Фактите могат да се разглеждат като събиране на данни и условия. Данните свързват стойността на характеристиките с дадено нещо, а условията извършват тестове на стойностите на характеристиките, за да определят дали това нещо представлява интерес, като правилната му класификация или дали се е случило дадено събитие.

Например, ако разполагаме с фактът:

Температурата < 0

Тогава температурата представлява фактът/данните, а условието е < 0

Правилата не взаимодействат директно с данните, а само с условия, единични или множествени (присъединени от логически оператори, показани на Таблица 12).

Факти / Данни	Условия	Правила
Сезон от годината Температура Зачервяване от вятъра Път Времето	$< 0, > 0$ Силно, Леко Хлъзгав, Не хлъзгав Студен, Затопляне, Топло	Помещение Ако (IF) Температурата < 0 И (AND) Ако (IF) Зачервяване от вятъра е силно ИЛИ (OR) Ако (IF) Пътят е хлъзгав Заклучение Тогава (THEN) Времето е студено

Таблица 12: Пример на части от система, основана на правила и взаимодействията между тях


Съществуват два начина дадено правило да задава нови стойности за данните:

- по задание, където стойността е директно зададена, и
- чрез твърдение. Твърдението само по себе си не присвоява стойност на данните, но условието действа като ограничение върху стойността на данните, като твърди, че трябва да бъде стойността, посочена от условието

На базата на разгледаните в дисертацията трудове в областта на прогнозиране на финансови времеви серии с невронни мрежи се предлага използването на няколко мрежови архитектури, по подобие на описания в предходните точки експеримент, за да се гарантира подбора на по-добър модел за тази жизнено важна част от експеримента. Избраните мрежови архитектури са тези на многослойния перцептрон, невронни мрежи с радиална базова функция и невронните мрежи с общата регресия с които авторът има богат опит. Моделите невронни мрежи ще бъдат използвани да прогнозира бъдещото развитие на основните 4 показателя на базата на които се съставя класирането на емисиите за състава на Sofia. Идеята е да бъдат направени 2 вида прогнози: Първи за един ден напред на базата на първоначално наличната информация за целия оставащ период и втори, да бъдат формирани динамични данни, като резултатите за всеки следващ ден напред, продуцирани от мрежите бъдат включени в данните за обучение.

3.4.4 Представяне на хибридният модел

Схематично, хибриден модел изграден от невронни мрежи и системи основани на правила, предназначен за търговия на БФБ – София е представена на Фигура 21.



Фигура 21: Хибриден модел изграден от невронни мрежи и системи основани на правила

Както е видно от схемата на предложения модел, модула със системи основани на правила се захранва с информация от дневните бюлетини на БФБ и ЦД, за период от 5 месеца, като това изгражда модула със знания. Модула с правила на този етап е съставен от общите критерии за определяне на индекса Sofix. Продуцирания резултат, под формата на списък с компании отговарящи на условията се подават на модула с Невронни мрежи, който на свой ред извършва процес по прогнозиране на всеки един от четирите количествени критерия на базата на данни за тези критерии за всяка отделна акция от списъка. След като невронните мрежи извършат прогнозирането, получената нова база данни (изградена от реални и прогнозни стойности) се подава към системата базирана на правила за съставяне на ново класиране на компаниите. То определя окончателния прогнозиран състав на индекса 1 месеца в аванс и модела генерира своите сигнали за покупка или продажба.

Характерна особеност на количествените правила за определяне на емисиите, които стават част от Sofix е един изключително труден за прогнозиране елемент а именно т.нар. спред между цените „купува“ и „продава“, който се изчислява след дискретни наблюдения, като активните в системата за търговия поръчки се тестват ежедневно за едновременното изпълнение на входящи поръчки „продава“ и „купува“ с обща стойност от 20 000 (двадесет хиляди) лева, от 15 000 (петнадесет хиляди) лева и от 10 000 (десет хиляди) лева в четири произволно избрани момента по време на търговска сесия, по един в интервалите 10:00:00 – 11:30:00, 11:30:01 – 13:00:00, 13:00:01 – 15:30:00, 15:30:01 – 16:55:00. Тази особеност кара авторът да се замисли за включването на допълнителен елемент в модела, посветен за следенето на този компонент, като подходяща техника от областта на Изкуствения интелект би била размити системи за вземане на решения [135],[136] и [137].

На този етап, авторът смята, че представения хибриден модел за прогнозиране състава на индекса на БФБ – София: Sofix, съставен от системи основани на правила и невронни мрежи, който спокойно може да се причисли и към полето на “Big Data” изследванията поради обема на обработваната информация е обещаващ и има огромен потенциал да влезе в употреба както с цел експериментиране въз основа на данни от минали периоди с академични цели като например разобличаване на теорията за ефективния пазар, така и за подпомагането на реално действаща стратегия за търговия съобразена с условията на ниска ликвидност, отсъствие на богат инструментариум за търговия (практическата невъзможност за къси продажби, маржин покупки и липсата на деривативни инструменти) и липса на много на брой качествени емитенти с които може да се характеризира българския борсов пазар.

ГЛАВА IV: НАСОКИ НА БЪДЕЩИ ИЗСЛЕДВАНИЯ

Насоките за бъдещи изследвания, могат да бъдат очертани по две взаимно преплитачи се линии. Първата, по отношение на усъвършенстване на моделите за прогнозиране на капиталови пазари основани на невронни мрежи, чрез експерименти с други видове мрежи, архитектури, обучаващи техники и различно предварително обработване на информацията, която се подава в моделите с цел подобряване на прогностичните им способности. В тази насока авторът вижда потенциал в изследване на възможностите, които предлагат сравнително нови техники в областта на машинното обучение, като машините с поддържащи вектори (SVMs) [138] която се използва за регресия и класификация. Втората насока е доразвиване на предложения хибриден модел от невронни мрежи и системи основани на правила за прогнозиране на слабо развити и ниско ликвидни капиталови пазари насочено в посока, допълването му с включване на допълнителен елемент, който да се заеме със силно субективния количествен елемент за оценяване на ликвидността на акциите, а именно изпитването за спред между цените „купува“ и „продава“ с определени суми, който се изчислява след дискретни наблюдения по преценка на борсовия оператор по време на борсовата сесия. Авторът намира за подходяща за тази цел техниката от областта на Изкуствения интелект - размитите системи за взимане на решения.

Също така, би могло да се работи в посока изпитването и прилагането на тези модели на други капиталови пазари, със сходни показатели на българския, макар това да е свързано с множество други условия, като специфичните условия за търговия на подобен род пазари, различните правила за определяне, поддържане и ребалансиране на индекси и много други.

ГЛАВА V: ЗАКЛЮЧЕНИЕ - РЕЗЮМЕ НА ПОСТИГНАТИТЕ РЕЗУЛТАТИ С ДЕКЛАРАЦИЯ ЗА ОРИГИНАЛНОСТ НА ДИСЕРТАЦИОННИЯ ТРУД

ЗАКЛЮЧЕНИЕ

В заключение, могат да бъдат направени следните констатации на базата на проведените експерименти и предложения хибриден модел. В първият експеримент с многослоен перцептрон, извършването на осредняване на подаваните данни в условията на неликвиден пазар дава резултат и успява да намали грешката при валидиращия сет от данни значително. Наблюдава се тенденцията, грешката да продължава да намалява с удължаване на периода на осредняване до 7 дни. След това грешката започва отново да нараства и продължаване на осредняването губи смисъл. Епохите на обучение чрез обратно разпространение на грешката са ограничени до 100 броя, поради времеемкостта на този вид обучение и липсата на по-добри резултати при провеждане на експерименти без да бъде зададен максимален брой цикли.

Невронните мрежи, и многослойния перцептрон в частност се представят добре когато прогнозира на базата на времеви серии от информация за пазари в консолидираща фаза и губят точност на прогнозите си в условията на тренд, като това е особено силно изразено при низходящ тренд.

Друго наблюдение от проведения експеримент на база на осреднените данни е продължаващото по-лошо представяне на невронните мрежи, използващи пълния набор от параметри за обучение, изпитване и валидиране, съставен от 10 параметъра.

Вторият експеримент, проведен с три вида невронни мрежи, доведе до някои изненадващи резултати. На първо място, доброто представяне, което показват, както невронните мрежи с обща регресия, така и тези с радиална базова функция. Те изглежда се справят много по-добре в моделирането на данните на входовете си, като успяват да продуцират еднакво добри резултати резултати изолирайки различен брой входящи параметри. Например втората най-добра мрежа с обща регресия използва два неврона във входящия си слой отговарящи съответно за целевата променлива – последна стойност на индекса за деня (стойност на затваряне) и най-ниската стойност за деня, докато втората най-добра мрежа с радиална базова функция използва всичките 4 входни параметри (освен горните две и стойност на отваряне и най-ниска стойност за деня). Макар резултатите на многослойния перцептрон да са по-добри от постигнатите по време на провеждането на първия експеримент, те остават в пъти по-лоши от тези на останалите модели. Тази тенденция е видима не само при валидиращите данни, а на база данните за грешката по време на обучението и при изпитването на мрежата.

По време на втората част от втория експеримент за прогнозиране (прогнозирането на по-волатилния индекс), отново се потвърждават добрите резултати, които показват невронните мрежи с обща регресия. Като цяло, грешките и при трите разновидности растат спрямо тези продуцирани при прогнозирането на Sofix, нещо което вероятно се дължи и на по-голямата волатилност на индекса BG40 и на някои други фактори свързани със селекцията на входните данни. Големи размествания в класирането на моделите спрямо предходния експеримент не се наблюдава. Донякъде, за неочаквано може да се счете използването на 2 параметъра на входа от най-сполучливия модел, което се случва за първи път, но и при предходния случай, разликата между, този залагащ само на търсената променлива и втория най-успешен бе твърде малка.

Резултатите на многослойния перцептрон са по-лоши от постигнатите по време на провеждането на теста върху Sofix, но това, както вече бе споменато е общата тенденция. При тях се наблюдава доближаване до резултатите на мрежите с радиална

базова функция, което може да се приеме като позитивен фактор. Резултатите на трите модела по отношение на грешката по време на обучението и тази при изпитващия сет запазват тенденциите наложени от базовото оценяване.

Обобщено, може да се посочи, че резултатите от изследването на способностите за прогнозиране на трите вида невронни мрежи могат да се определят като полезни. Постоянството в резултатите на невронните мрежи с обща регресия ги прави безапелационни победители в това своеобразно съревнование. По този начин, те потвърждават до голяма степен позитивните си атестации, отбелязани априори проведените експерименти, като по-бързи и успешни, способни да се справят с данни съдържащи отклонения.

Много добро и постоянно представяне се отчита и за модела използващ радиална базова функция. Те показват успех при боравенето с повече от един входящ параметър за прогнозиране на целевата променлива, което ги отличава от останалите.

Многослойния перцептрон може да бъде определен като най-лошо представилата се мрежа в прогнозирането и на двата индекса, като не добрите й резултати се потвърждават, както от размера на грешката по време на валидиращите данни, така и от този при обучението и изпитването му. Въпреки, че размерът на продуцираната от него грешка не е голям и ако се абстрахираме от резултатите на другите модели, прогнозите му може да бъдат сметени за задоволителен и надеждни, гледайки нещата на релативна база е трудно да бъдем самодоволни. Също така е факт, че при по-волатилните данни за индекса BG40 разликата от другите модели и по-конкретно от тези с радиална базова функция се стопява значително.

На база на проведеното изследване на възможността за прогнозиране на индексите на българския фондов пазар с три от многобройните видове изкуствени невронни мрежи може да бъде направено заключението, че този клас модели от областта на Изкуствения интелект може да се справи успешно със задачата да прогнозира бъдещи стойности свързани с финансови инструменти, търгувани на българския капиталов пазар, на база на времеви серии финансова информация. Веднага трябва да бъде направено уточнението, че това в никакъв случай не означава, че те са способни да осъществяват успешна търговия на капиталовите пазари като самостоятелна стратегия за генериране на сигнали за покупко-продажби, още повече, че и проведените експерименти не предполагат такава възможност. За сметка на това, със сигурност те са способни да подпомогнат един по-комплексен модел насочен към действителна търговия на фондовия пазар, дори в условия като тези на българския пазар.

Като логично продължение на заключението от първите два експеримента идва предложеният от автора хибриден модел от невронни мрежи и системи основани на правила, предназначен за търговия на БФБ – София. Моделът е работоспособен и приложим в условията на нисколиквиден и слабо развит капиталов пазар. Той е обещаващ и има огромен потенциал да влезе в употреба както с цел експериментиране въз основа на данни от минали периоди с академични цели като потвърждаване или отхвърляне на теорията за ефективния пазар, така и за подпомагането на реално действаща стратегия за търговия съобразена с условията на ниска ликвидност, отсъствие на богат инструментариум за търговия (практическата невъзможност за къси продажби, маржин покупки и липсата на деривативни инструменти) и липса на много на брой качествени емитенти с които може да се характеризира българския борсов пазар.

РЕЗЮМЕ НА ПОСТИГНАТИТЕ РЕЗУЛТАТИ

В резултат от проведените изследвания представени в настоящия дисертационен труд, са постигнати следните научно-приложни и приложни резултати:

Направи се изследвани възможностите за прогнозиране на капиталовите пазари с невронни мрежи. Изследвано бе формирането, развитието и способността на невронните мрежи за прогнозиране на капиталовия пазар. Особено внимание бе обърнато на еволюцията и развитието на това начинание в световен мащаб през годините, както и на различните подходи, които са предлагани и използвани.

Проведе се изследване на състоянието в областта на прогнозирането на капиталовите пазари с невронни мрежи, извършено с разглеждане на голям брой книги, статии и публикации по темата, от които подробно бяха разгледани и анализирани повече от 50 труда, от които бяха направени интересни изводи за предпочитани от авторите модели, архитектури и методи на обучение на невронните мрежи. Също така, се направи обобщение на капиталови пазари, борсови индекси и видовете входящи данни, прогнозирани и използвани от моделите, както и изследване на използването на други техники от полето на Изкуствения интелект за прогнозиране на капиталов пазар.

Като част от изследването на българския фондов пазар, който е обект на прогнозиране се направи представяне на българския регулиран капиталов пазар в лицето на БФБ – София и бяха определени основните качествени и количествени различия между него и развитите борси по света, на базата на които той се определя като не добре развит.

Предложен е хибриден модел от невронни мрежи и системи основани на правила за прогнозиране на слабо развит и ниско ликвиден капиталов пазар какъвто е този в България. Авторът намира този модел е работоспособен и изключително обещаващ, разполагащ с огромен потенциал да влезе в употреба както желаещите да експериментират на база на данни от минали периоди за академични цели като например разобличаване на „Хипотезата за ефективния пазар”, така и за подпомагането на реално действаща стратегия за търговия съобразена с условията на ниска ликвидност, отсъствие на богат инструментариум за търговия

Проведените експерименти със създадения хибриден модел в реалните условия на българския капиталов пазар, на база на данни от минали периоди препотвърждават способностите му.

Обобщените резултати от проведените експерименти и постигнатите резултати могат да бъдат обобщени по следния начин:

На базата на придобитите знания от изследването на предишните опити в областта се направи опит да бъде избрана подходяща структура на невронна мрежа за целите на прогнозиране на ниско ликвиден финансов пазар какъвто е българския. Съобразявайки се с тази особеност на родния капиталов пазар, се направена подходяща селекция на входящи параметри за избрания модел за прогнозиране, така че да бъде той в състояние да направи точни предвиждания. Успешно извършена бе предварителна подготовка и обработка на данните, като това доведе до значителни подобрения на продуцираните от моделите изходни данни. Резултатите, ясно показват ефективността от извършване на трансформация от стойности в изменения и осредняване на входящите данни. Това успява да намали грешката при валидиращите данни значително. Също така се наблюдава зависимост на размера на калкулираната грешка на всички използвани модели от с т. нар. състояние на пазара. Установи се, че при големите амплитуди в стойността на разглежданите борсови индекси, известни с термина волатилност, тенденцията при който е да се повишава в периоди когато пазара се намира в тренд и особено много при низходящ тренд, когато цените на акциите преминават през

продължителен период на намаление, изкуствените невронни мрежи губят точност на прогнозите си. Това е особено силно изразено при низходящ тренд. Осъществи се наблюдение на тенденция невронните мрежи да се представят добре когато прогнозират на базата на времеви серии от финансова информация за пазари в консолидираща фаза. Експерименти за прогнозиране на индекси на БФБ – София се проведеха с 3 вида невронни мрежи като постигнатите резултати се определят като добри и изключително интересни. Открита е любопитна тенденция, а именно, че най-често използвания вид невронна мрежа, според изследваните и описани от автора научни трудове в областта, този на многослойния перцептрон не се представя толкова успешно, колкото другите две разновидности – невронната мрежа с радиална базова функция и най-точно прогнозираната невронна мрежа с обща регресия. Те изглежда се справят много по-добре в моделирането на данните на входовете си, като успяват да продуцират еднакво добри резултати изолирайки различен брой входящи параметри. Например една от най-добре представилите се мрежа с обща регресия използва два неврона във входящия слой отговарящи съответно за целевата променлива – последна стойност на прогнозирания индекс за деня и най-ниската стойност за деня, докато друг много успешен модел на мрежа с радиална базова функция използва всичките предоставени ѝ 4 входни параметри. Авторът намира опита да бъде поставена под съмнение валидността на „Хипотезата за ефективния пазар“ за успешен, като ниските нива на реализирана грешка от моделите дават повод да смята, че нови и по-задълбочени изследвания в областта е вероятно да подобрят още повече резултатите.


ДЕКЛАРАЦИЯ ЗА ОРИГИНАЛНОСТ НА ДИСЕРТАЦИОННИЯ ТРУД

Декларация за оригиналност на резултатите

Декларирам, че настоящата дисертация съдържа оригинални резултати, получени при проведени от мен научни изследвания {с подкрепата и съдействието на научния ми ръководител}. Резултатите, които са получени, описани и/или публикувани от други учени, са надлежно и подробно цитирани в библиографията.

Настоящата дисертация не е прилагана за придобиване на научна степен в друго висше училище, университет или научен институт.

Подпис:



ГЛАВА VI: ПУБЛИКАЦИИ ПО ТЕМАТА НА ДИСЕРТАЦИЯТА И ЦИТИРАНИЯ

Публикации по темата на дисертацията

- Shahpazov V., V. Veleв, L. Doukovska - Design and Application of Artificial Neural Networks for Predicting the Values of Indexes on the Bulgarian Stock Market, Proc. of the Signal Processing Symposium – SPS’13, Jachranka Village, Poland, CD, ISBN 978-1-4673-6319-8-13- 2013 IEEE, 2013.
<http://ieeexplore.ieee.org/search/searchresult.jsp?newsearch=true&queryText=signal+processing+symposium+sps+2013&x=0&y=0>
- Shahpazov V., V. Veleв, L. Doukovska - Forecasting Price Movement of Sofix Index on the Bulgarian Stock Exchange – Sofia Using an Artificial Neural Network Model, Proc. of the International Symposium on Business Modeling and Software Design – BMSD’13, Noordwijkerhout, The Netherlands, ISBN 978-989-8565-56-3, pp. 298-303, 2013.
<http://www.is-bmsd.org/Documents/ProceedingsOfThirdBMSD.pdf>
- Shahpazov V., Doukovska L., Forecasting financial markets with artificial intelligence, Proc. of the International Workshop on Advanced Control and Optimisation: Step Ahead ACOSA’14 Bankya, Bulgaria, Prof. Marin Drinov Publishing House, 2014, ISSN: 1314-4634. 67-74.
<http://iict.bas.bg/acomin/news/8-10-May-2014.pdf>
- Veselin L. Shahpazov, Lyubka A. Doukovska, Dimitar N. Karastoyanov - Artificial Intelligence Neural Networks Applications in Forecasting Financial Markets and Stock Prices, Proc. of the International Symposium on Business Modeling and Software Design – BMSD’14, Luxemburg, Grand Duchy of Luxemburg, 24 - 26 June 2014, ISBN: 978-989-758-032-1, pp. 282-288, 2014.
<http://www.is-bmsd.org/Documents/ProceedingsOfFourthBMSD.pdf>
- Шахпазов В., Високочестотната търговия. Списание Техносфера ISSN 1313-3861 Брой 4 (34)/2016 г.
- Shahpazov V.L., Popchev I., A Neural Network and Rule-based Systems Hybrid Model for Forecasting the Capital Market, „Journal of Informatics and Innovative Technologies”, Plovdiv, 2019 г. ISSN 2682-9517 (print)

Цитирания

1. Samit Bahnja, Abhishek Das, Impact of Data Normalization on Deep Neural Network for Time Series Forecasting, 2018
2. Cavalcante R.C., Brasileiro, R.C., Souza V.L., Nobrega J.P., Oliveira A.L., Computational Intelligence and Financial Markets: A Survey and Future Directions. Expert Systems with Applications, 55, pp. 194-211, 2016.

3. Gabriel F.C. Campos, Rodrigo A. Igawa, Jos'e L. Seixas Jr., Alex M.G. de Almeida, Rodrigo Capobianco Guidoy, Sylvio Barbon Jr., Supervised Approach for Indication of Contrast Enhancement in Application of Image Segmentation, Proc. Of the Eighth International Conference on Advances in Multimedia, ISBN 978-1-61208-452-7, pp. 12-18, 2016.
4. Tarun Dash, Vinayak Jaiswal, Anoosha Sagar, Gaurav Vazirani, Nupur Giri, Analysis of associativity among mirror neurons for financial profiling, Proc. Of the Second International Conference on Cognitive Computing and Information (CCIP), DOI 10.1109/CCIP.2016.7802869, 2016.
5. Tarun Dash, Vinayak Jaiswal, Anoosha Sagar, Gaurav Vazirani, Nupur Giri, Analysis of associativity among mirror neurons for financial profiling: A proposal, Proc. of the International Conference on Computing Communication Control and automation (ICCUBE), DOI 10.1109/ ICCUBE.2016.780034, 2016.
6. Tukur U.M., S.M. Shamsuddin, Radial Basis Function Neural Network Learning with Modified Backpropagation Algorithm. Indonesian Journal of Electrical Engineering and Computer Science, vol. 13, 2, pp. 369-378, 2015

Всички цитирания се отнасят към следната публикация:

Shahpazov V., V. Velevev, L. Doukovska - Design and Application of Artificial Neural Networks for Predicting the Values of Indexes on the Bulgarian Stock Market, Proc. of the Signal Processing Symposium – SPS'13, Jachranka Village, Poland, CD, ISBN 978-1-4673-6319-8-13- 2013 IEEE, 2013.

ГЛАВА VII: УЧАСТИЯ В ПРОЕКТИ

- Проект на ИИКТ - “Интелигентна функционална диагностика на сложни системи и изследване на структури при неопределеност и риск” (2011-2014).
- Проект на ИЕМПАМ – “Изграждане и развитие на млади висококвалифицирани изследователи за ефективно прилагане на биомедицинските изследвания за подобряване качеството на живот”, BG051PO001-3.3.06-0048/04.10.2012 г.

ГЛАВА VIII: БИБЛИОГРАФИЯ

1. Keeley, B. Income Inequality: The Gap between Rich and Poor, OECD Insights, (2015), OECD Publishing, Paris. <http://dx.doi.org/10.1787/9789264246010-en>
2. <https://data.worldbank.org/>
3. <https://www.investopedia.com>
4. <https://robinhood.com/>
5. Tan, C., An Artificial Neural Networks Primer with Financial Applications: Examples in Financial Distress Predictions and Foreign Exchange Hybrid Trading System
6. Fama, E., "Efficient Capital Markets: A Review of Theory and Empirical Work". Journal of Finance (1970).
7. Saad, E. W., Prokhorov, D. V., and Wunsch, D. C. "Comparative Study of Stock Trend Prediction Using Time Delay, Recurrent and Probabilistic Neural Networks". IEEE Transactions on Neural Networks. Vol 9, Issue 6: 1456–1470. (1998), CiteSeerX 10.1.1.184.7175. doi:10.1109/72.728395. PMID 18255823.CS1
8. Granger, C. W., Morgenstern, O. "Spectral Analysis Of New York Stock Market Prices". Kyklos. 16 (1): 1–27, (2007) doi:10.1111/j.1467-6435.1963.tb00270.x.
9. Jegadeesh, N; Titman, S (1993). "Returns to Buying winners and selling losers: Implications for stock market efficiency". Journal of Finance. 48 (1): 65–91. doi:10.1111/j.1540-6261.1993.tb04702.x.
10. Jegadeesh, N; Titman, S (2001). "Profitability of Momentum Strategies: An evaluation of alternative explanations". Journal of Finance. 56 (2): 699–720. doi:10.1111/0022-1082.00342.
11. Fama, E; French, K (2008). "Dissecting Anomalies". Journal of Finance. 63 (4): 1653–78. doi:10.1111/j.1540-6261.2008.01371.x.
12. George E. P. Box, Gwilym M. Jenkins, Time Series Analysis: Forecasting and Control 5th Edition. Wiley (2015), ISBN: 978-1-118-67502-1
13. Шахпазов В., Високочестотната търговия. Списание Техносфера ISSN 1313-3861 Брой 4 (34), стр. 53- 65, 2016 г.
14. Trippi R., Chorafas D. N., Chaos Theory in the Financial Markets, McGraw-Hill, Inc. New York, NY, USA, 1994, ISBN:1557385556
15. Тенева Г., Финансови Пазари, Fast Books Print, Пловдив, 2017, ISBN: 978-619-7312-88-1

16. Markets in Financial Instruments (MiFIR) - Regulation (EU) No 600/2014
https://ec.europa.eu/info/law/markets-financial-instruments-mifir-regulation-eu-no-600-2014_en
17. Turing, A., "Machine Intelligence", in Copeland, B. Jack (ed.), The Essential Turing: The ideas that gave birth to the computer age, Oxford: Oxford University Press, p. 412, ISBN 978-0-19-825080-7
18. Winston, P., Artificial Intelligence, Third Edition, Addison-Wesley, 1992.
19. Rich E., Knight K., Artificial Intelligence, McGraw-Hill, (2017), ISBN-10: 0070087709
20. Meyer, Y. Wavelets and Operators. Cambridge: Cambridge University Press. (1992), ISBN 0-521-42000-8.
21. Holland, J., Adaptation in Natural and Artificial Systems. Cambridge, MA: MIT Press. (1992) ISBN 978-0262581110.
22. Pal S., Srimani P. K., Neurocomputing motivation, models, and hybridization, Published in Computer (1996) DOI:10.1109/MC.1996.485890
23. Lawrence R., 1998, Using neural networks to forecast stock market prices
24. Haykin, S., Neural networks and learning machines, 3rd ed.p. cm. Rev. ed of: Neural networks. 2nd ed., 1999. ISBN-13: 978-0-13-147139-9 ISBN-10: 0-13-147139-2
25. Beale R., Jackson T., Neural Computing - An Introduction, Published by Institute of Physics Publishing (1990) ISBN 10: 0852742622 /ISBN 13: 9780852742624
26. <http://www.research.ibm.com>
27. Eberhart R., Dobbins R., Neural Networks P.C. Tools, Russell, 1990, ISBN: 9781483297002
28. James, W., Psychology: Briefer Course, Holt, New York, 1890.
<https://archive.org/details/psychologybriefe00willuoft/page/n11>
29. McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. The Bulletin of Mathematical Biophysics, 5, 115-133.
<http://dx.doi.org/10.1007/BF02478259>
30. Hebb, D.O. (1949) The Organization of Behavior. A Neuropsychological Theory. John Wiley and Sons, Inc., New York.
31. Rosenblatt, F., "The perceptron: a probabilistic model for information storage and organization in the brain", Psychological Review, 65: pp.386-408, 1958.
32. Widrow B. and Hoff M. E., "Adaptive Switching Circuits," 1960 IRE WESCON Convention Record, 1960, pp. 96-104.

33. Minsky M. and Papert S., "Perceptrons," MIT Press, Cambridge, 1969
34. Rumelhart E., David McClelland, James L., James 1986, Parallel distributed processing: explorations in the microstructure of cognition. Volume 1. Foundations
35. Brian D. Ripley, Statistical Aspects of Neural Networks, 1993, DOI: 10.1007/978-1-4899-3099-6_2
36. Bryson A., and Ho Y., Applied Optimal Control, Blaisdell, New York, (1969)
37. Werbos P., John, Paul, 1974, Beyond regression: new tools for prediction and analysis in the behavioral sciences
38. Cowan JD, Sharp DH. Neural nets. Quarterly Reviews of Biophysics. 21: 365-427. PMID 3065814 DOI: 10.1017/S0033583500004492
39. Terrence J. Sejnowski, Charles R. Rosenberg, Neurocomputing: foundations of research Pages 661-672, 1988, ISBN:0-262-01097-6
40. Martin G. L. and Pittman J. A., Recognizing hand-printed letters and digits using backpropagation learning. Advances in Neural Information Processing Systems 2, pp 405 – 414, Morgan Kaufmann, San Mateo CA, 1990
41. Hu M. J. C., Halbert E. Root, An Adaptive Data Processing System for Weather Forecasting <https://doi.org/10.1175/1520-0450> (1964)
42. Werbos P.J., "Generalization of back propagation with application to a recurrent gas market model," Neural Networks, vol. 1, pp. 339-356, 1988
43. White H., "Economic prediction using Neural Networks: The case of IBM daily stock returns", In Proc. of the IEEE International Conference on Neural Networks, 1988, pp. 451-458.
44. Kimoto T., Asakawa K., Yoda M., and Takeoka M., "Stock market prediction system with modular neural network," Proceedings of the International Joint Conference on Neural Networks, 1990, pp. 1-6.
45. Kamijo K. and Tanigawa T. "Stock market pattern recognition – a recurrent neural network approach" Proc. IJCNN 1990, vol. 1 pp. 215-21 San Diego, June 1990.
46. Kamley S., Jaloree S., Thakur R. S., Performance Forecasting of Share Market using Machine Learning techniques: A Review, India International Journal of Electrical and Computer Engineering (IJECE) Vol. 6, No. 6, December 2016, pp. 3196~3204
47. Holland, J.H. (1975) Adaptation in Natural and Artificial Systems. University of Michigan Press, Ann Arbor. (2nd Edition, MIT Press, 1992.)
48. Bousquet, O.; von Luxburg, U.; Raetsch, G., eds. (2004). Advanced Lectures on Machine Learning. Springer-Verlag. ISBN 978-3540231226.

49. Yoon Y. and Swales G.. Predicting stock price performance: A neural network approach. In *Neural Networks in Finance and Investing*, chapter 19, pages 329–342. Probus Publishing Company, 1993.
50. Klimasauskas C.. Applying neural networks. In *Neural Networks in Finance and Investing*, chapter 3, pages 47–72. Probus Publishing Company, 1993.
51. Broomhead, D.S. and Lowe, D. (1988) Multi-Variable Functional Interpolation and Adaptive Networks. *Complex Systems*, 2, 327-355.
52. Spetch D., A General Regression Neural Network, *IEEE Transactions on Neural Networks* Vol 2 No 6 November 1991.
53. Shih, Y., *Neuralystä User's Guide*, Cheshire Engineering Corporation, USA, pp.74, 1994.
54. Azoff, E. M., *Neural Network Time Series Forecasting of Financial Markets*, John Wiley & Sons, pp. 50-51, England, ISBN: 0-471-94356-8, 1994.
55. Lippmann, R. P., "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine*, pp. 4-23, April 1987.
56. Lawrence, S., Giles, C. L., and Tsoi, A. C., "What Size Neural Networks Gives Optimal Generalization? Convergence Properties of Backpropagation", Technical Report UMIACS-TR-96-22 and CS-TR-3617, Institute of Advanced Computer Studies, University of Maryland, College Park, MD 20742, 1996.
57. Baum, E. B. and Haussler, D., *Neural Computation* 1, 1988, 151–160.
58. Neural Network FAQ, Maintainer: Sarle, W. S., "How Many Hidden Units Should I Use?", July 27, 1996, Neural Network FAQ Part 1-7, [Online], Archive-name:aifaq/neural-nets/part3, Available: <ftp://ftp.sas.com/pub/neural/FAQ3.html>, [1996, August 30].
59. McCullagh, P. and Nelder, J. A. *Generalized Linear Models*, 2nd ed., Chapman & Hall, London, UK, 1989.
60. Sontag, E. D. (), "Feedback stabilization using two-hidden-layer nets", *IEEE Transactions on Neural Networks*, 3, 981-990, 1992.
61. Hornik, K., "Some new results on neural network approximation", *Neural Networks*, 6, 1069-1072, 1993.
62. Masters, T., *Practical Neural Network Recipes in C++*, Academic Press Inc., San Diego, CA., USA, ISBN: 0-12-479040-2, p.6, 1993.
63. Ripley B. D., *Neural Networks and Related Methods for Classification*, *Journal of the Royal Statistical Society. Wiley, Series B (Methodological)* Vol. 56, No. 3 (1994), pp. 409-456

64. Widrow, B. and Hoff, M. D., "Adaptive Switching Circuits", 1960 IRE WESCON Convention Record, Part 4, pp. 96-104, 1960.
65. Nelson, M. M. and Illingworth, W. T., A Practical Guide to Neural Nets, Addison-Wesley Publishing Company, Inc., USA, ISBN: 0-201-52376-0/0-201-56309-6, 1991.
66. Fu C. S., Wen F., Load frequency controller using genetic algorithm based on fuzzy gain scheduling of PI controller. Institute of Electronic Machines and Power Systems 26: 39-52, 1998.
67. Fallhman, S. E., Comments on comp.ai.neural-nets, Item 2198 [Internet Newsgroup].
68. Matsuba, I., "Neural sequential associator and its to stock price prediction" Proc. IECON 91, vol. 2 pp. 1476-9, Japan Nov. 1991.
69. Freisleben B. "Stock market prediction with back-propagation networks" 5th Intl. Conf. on the industrial and engineering application of artificial intelligence and expert systems, pp 451-60, Germany, June 1992.
70. Kamijo K. and Tanigawa, T. (1993), "Stock Price Pattern Recognition: A Recurrent Neural Network Approach", In Neural Networks in Finance and Investing.
71. Winston P., Winston, P. , Artificial Intelligence, Third Edition, Addison-Wesley, 1992.
72. Azoff, E.M., Neural Network Time Series Forecasting of Financial Markets. John Wiley and Sons, (1994), Chichester.
73. Kaastra I., Boyd M. " Forecasting futures trading volume using neural networks" Journal of Futures Markets Volume 15, Issue 8, pages 953–970, December 1995
74. Van Eyden R. J.. The Application of Neural Networks in the Forecasting of Share Prices. Finance and Technology Publishing, 1996.
75. Chang C., Urban W C.L. and Baldrige G.W., "A neural network approach to mutual fund net asset value forecasting" Omega Int. Mgmt Sci. 24 (2) 203-215 (1996)
76. Kuo R. J. L. C. Lee and C. F. Lee (1996) "Integration of Artificial Neural Networks and Fuzzy Delphi for Stock Market Forecasting" IEEE June 1073-1078
77. Kim S. H. and S. H. Chun. (1998) "Graded forecasting, using a array of bipolar predictions: application of probabilistic neural networks to stock market index" International Journal of Forecasting. 14 323 – 337.
78. Aiken, N. M., Bsad M. "Forecasting Market Trends with Neural Networks" Information System Management 16 (4) 42-48, (1998)
79. Edelman, D. P. Davy and Y. L. Chung "Using Neural Network Prediction to achieve excess returns in the Australia All Ordinaries index" In: Queensland Financial Conference Sept 30th Queensland University of Technology, (1999)

80. Thammamano A., Neuro-fuzzy Model for stock market Prediction” Proceedings of the Artificial Neural Network and Engineering Conference (ANNIE 99) NY ASME Press pp 587 – 591, (1999)
81. Trafalis, T. B.“ Support vector machine for regression and applications to financial forecasting” Proceedings of the Artificial Neural Network and Engineering Conference (ANNIE 99) NY ASME Press pp 1049 – 1054. (1999)
82. Tansel I. N., S. Y. Yang, G. Venkataraman, A. Sasirathsiri, W. Y. Bao and N. Mahandrakar.“Modelling Times Series Data by using Neural Networks and Genetic Algorithms” Proceedings of the Artificial Neural Network and Engineering Conference (ANNIE 99) NY ASME Press pp 1055 – 1060. (1999)
83. Garalaukas, A.“Neural Network Chaos and Computational algorithms of Forecast in Finance” Proceedings of the IEEE SMC Conference on Systems, man and Cybernetics 2, 638 – 643. (1999)
84. Chan, M. C. , C. C. Wong, and C-C Lam.“Financial Time Series Forecasting by Neural Network Using Conjugate Gradient Learning Algorithm and Multiple Linear Regression Weight Initialization”Dep. Of Computing, The Hong Kong Polytechnic University. (2000)
85. Kim, K. J. and I Han“Genetic Algorithm approach to feature discretization in artificial neural networks for the prediction of stock price index”Elsevier Science Ltd, Expert Systems with Applications, 19, 125 – 132. (2000).
86. Romahi, Y. and Q. Shen.“Dynamic Financial Forecasting with Automatically Induced Fuzzy Associacions”IEEE, 493 – 456. (2000)
87. Abraham, A. B. Nath and P. K. Mahanti“Hybrid Intelligent Systems for Stock Market Analysis”Computational Science, Springer-Verlag Germany Vassil Alexandrov et. al. (Eds.) ISBN 3-540-42233-1, SF USA , pp. 337 – 345. (2001)
88. Chao, L. and F. E. H. Tay.“Financial Forecasting Using Support Vector Machines”Neural Compt & Applic (2001) 10: 184 – 192
89. Hawarang, H. B.“Insight into neural network forecasting of time series corresponding to ARMA (p,q) structures” International Journal of Management Science, Omega, 29, 273 – 289. (2001)
90. Kuo, R. j., C. H. Chen and T. C. Hwang. “An intelligent stock trading decision support system through integration of genetic algorithm based on fuzzy neural network and artificial neural network.” Fuzzy sets and systems: 118 (1) (2001) pp. 21-45
91. Mark T. Leung , Hazem Daouk, An-Sing Chen Forecasting stock indices: a comparison of classification and level estimation models International Journal of Forecasting 16, 173-190

92. Heping Pan , Ima Tilakaratne , John Yearwood “Predicting Australian Stock Market Index Using Neural Networks Exploiting Dynamical Swings and Intermarket Influences”
93. Kalyvas E. , Using Neural Networks and Genetic Algorithms to predict stock market returns, Department Of Computer Science The University of Manchester, October 2001
94. Chen A.S., Leung M.T., Daouk H., Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index Computers & Operations Research Volume 30, Issue 6, May 2003, Pages 901–923
95. Versace M., Bhatt R., Hinds O., Shiffer M., Predicting the exchange traded fund DIA with a combination Expert Systems with Applications 27 (2004) 417–425 of genetic algorithms and neural networks
96. Kim, W. B. Lee, Stock Market Prediction using artificial neural networks with optimal feature transformation Neural Comput & Applic 13 (2004) 255- 260;
97. Kim O., Artificial neural networks with evolutionary instance selection for financial forecasting, Expert Systems with Applications Expert Systems with Applications Volume 30, Issue 3, April 2006, Pages 519–526
98. Madden, Michael G.; O'Connor, Niall Neural Network Approach to Predicting Stock Exchange Movements using External Factors Applications and Innovations in Intelligent Systems XIII 2006, pp 64-77
99. Tilakaratne C.D., Mammadov M.A., Morris S.A. Predicting Trading Signals of Stock Market Indices Using Neural Networks. In: Wobcke W., Zhang M. (eds) AI 2008: Advances in Artificial Intelligence. AI 2008. Lecture Notes in Computer Science, vol 5360. Springer, Berlin, Heidelberg
100. Maciel L., Bellini R., Design a Neural Network for Time Series Financial Forecasting: Accuracy and Robustness Analysis, Instituto de Economia (IE), Universidade Estadual de Campinas (UNICAMP)
101. Hadavandi E., Shavandi H., Ghanbari A., Integration of genetic fuzzy systems and artificial neural networks for stock price forecasting Knowledge-Based Systems, Volume 23, Issue 8, December 2010, Pages 800-808
102. Gosh A., Comparative study of Financial Time Series Prediction By Artificial Neural Network with Gradient Descent Learning BRAIN Feb2012, Vol. 3 Issue 1, p41-49
103. Chen Z. and Du X., Study of Stock Prediction Based on Social Network, 2013 International Conference on Social Computing September 08-September 14 Alexandria, VA, USA
104. Adebisi A. A., Adewumi A. O., and Ayo C. K., Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction, Journal of Applied Mathematics Volume 2014, Article ID 614342

105. Sheta A. F., Elsir S. M., Faris A. H., A Comparison Between Regression, Artificial Neural Networks and Support Vector Machines for Predicting Stock Market Index, (IJARAI) International Journal of Advanced Research in Artificial Intelligence, Vol. 4, No.7, 2015
106. Qiu M, Song Y., Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model. PLoS ONE 11(5): e0155133. doi:10.1371/journal.pone.0155133(2016)
107. David M. Q. Nelson; Adriano C. M. Pereira, Stock market's price movement prediction with LSTM neural networks, 2017, DOI: 10.1109/IJCNN.2017.7966019 Conference: 2017 International Joint Conference on Neural Networks (IJCNN)
108. Chong E., Han C., Park F. C., Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies, Expert Systems With Applications 83 (2017) 187–205
109. Rezaee M.J., Jozmaleki M., Valipour M., Integrating dynamic fuzzy C-means, data envelopment analysis and artificial neural network to online prediction performance of companies in stock exchange, Physica A (2017), <http://dx.doi.org/10.1016/j.physa.2017.07.017>
110. Tabari N., Seyeditabari A., Peddi T., Hadzikadic M., Zadrozny W. (2019) A Comparison of Neural Network Methods for Accurate Sentiment Analysis of Stock Market Tweets. In: Alzate C. et al. (eds) ECML PKDD 2018 Workshops. MIDAS 2018, PAP 2018. Lecture Notes in Computer Science, vol 11054. Springer, Cham
111. Chopra S. et al., Artificial Neural Networks Based Indian Stock Market Price Prediction: Before and After Demonetization J Swarm Intel Evol Comput 2019, 8:1 DOI: 10.4172/2090-4908.1000174
112. Huang Y., Capretz L. F., Ho D., Neural Network Models for Stock Selection Based on Fundamental Analysis, 32nd Canadian Conference on Electrical & Computer Engineering, Edmonton, Canada, pages 1-4, IEEE Canada, May 2019.
113. Атанасова Т., Симеонова В., „Възможности За Прогнозиране На Борсови Индекси С Неврони Мрежи и Генетични Алгоритми“, катедра “Информатика”, Икономически университет - Варна 2008 г
114. Балабанов Т., Дисертация: РАЗПРЕДЕЛЕНА СИСТЕМА ЗА ПРОГНОЗИРАНЕ НА ВРЕМЕВИ РЕДОВЕ С ЕВОЛЮЦИОННИ АЛГОРИТМИ И ИЗКУСТВЕНИ НЕВРОННИ МРЕЖИ ИИКТ-БАН, София, 2017
115. <http://karollbroker.bg/blog/wp-content/uploads/2018/05/prezentatsiya-pobeditel-p%27rvo-trimesechie.pdf>
116. İcan Ö., Çelik T. B., Stock Market Prediction Performance of Neural Networks:A Literature Review, International Journal of Economics and Finance; Vol. 9, No. 11; 2017 ISSN 1916-971X E-ISSN 1916-9728

117. Tkáč M., Verner R., Artificial neural networks in business: Two decades of research, *Applied Soft Computing* 38 · October 2015
118. Shahpazov V., Doukovska L.; Karastoyanov D. and (2014). Artificial Intelligence Neural Networks Applications in Forecasting Financial Markets and Stock Prices. In *Proceedings of the Fourth International Symposium on Business Modeling and Software Design - Volume 1: BMSD*, ISBN 978-989-758-032-1, pages 282-288. DOI: 10.5220/0005427202820288
119. Shahpazov V., Doukovska L., Forecasting financial markets with artificial intelligence, *Proc. of the International Workshop on Advanced Control and Optimisation: Step Ahead ACOSA'14* Bankya, Bulgaria, Prof. Marin Drinov Publishing House, 2014, ISSN: 1314-4634. 67-74.
120. Shahpazov V., Velez V., Doukovska L. - Forecasting Price Movement of Sofix Index on the Bulgarian Stock Exchange – Sofia Using an Artificial Neural Network Model, *Proc. of the International Symposium on Business Modeling and Software Design – BMSD'13*, Noordwijkerhout, The Netherlands, ISBN 978-989-8565-56-3, pp. 298-303, 2013.
121. Bishop C., *Neural Networks for Pattern Recognition*, Oxford University Press, Inc. New York, NY, USA ©1995 ISBN:0198538642
122. Sheppard D. G., Hunt B. R., and Marcellin M. W., Iterative multiframe superresolution algorithms for atmospheric-turbulence-degraded imagery, *Journal of the Optical Society of America A* Vol. 15, Issue 4, pp. 978-992 (1998) •<https://doi.org/10.1364/JOSAA.15.000978>
123. Hilbe J. M., *STATISTICA 7 An Overview*, Pages 91-94, Published online: 01 Jan 2012 <https://doi.org/10.1198/000313007X172998>
124. Shahpazov V., V. Velez, L. Doukovska - Design and Application of Artificial Neural Networks for Predicting the Values of Indexes on the Bulgarian Stock Market, *Proc. of the Signal Processing Symposium – SPS'13*, Jachranka Village, Poland, CD, ISBN 978-1-4673-6319-8-13- 2013 IEEE, 2013.
125. Edelsbrunner H., O'Rourke J., and Seidel R., Constructing Arrangements of Lines and Hyperplanes with Applications, *SIAM J. Comput.*, 1986 15(2), 341–363. (23 pages) <https://doi.org/10.1137/0215024>
126. Haykin S., *A Comprehensive Foundation*, Prentice Hall PTR Upper Saddle River, NJ, USA ©1994 ISBN 0023527617
127. Kohonen T., Improved versions of learning vector quantization, 1990 IJCNN International Joint Conference on Neural Networks, DOI: 10.1109/IJCNN.1990.137622
128. <https://statistica.software.informer.com/>

129. Spetch D., A General Regression Neural Network, IEEE Transactions on Neural Networks Vol 2 No 6 November 1991.
130. <https://www.ecb.europa.eu/ecb/>
131. Shahpazov V. L., Popchev I., A Neural Network and Rule-based Systems Hybrid Model for Forecasting the Capital Market, „Journal of Informatics and Innovative Technologies”, Plovdiv, 2019 г. ISSN 2682-9517 (print)
132. <https://www.bse-sofia.bg/>
133. <http://www.csd-bg.bg/>
134. Grosan C., Abraham A. (2011) Rule-Based Expert Systems. In: Intelligent Systems. Intelligent Systems Reference Library, vol 17. Springer, Berlin, Heidelberg DOI <https://doi.org/10.1007/978-3-642-21004-4>
135. Peneva V., Popchev I. Fuzzy Multicriteria Design Making, Cybernetics and Information Technologies Vol. 2 №1 2002, 16-26, ISSN:1311-9702
136. Popchev I., Orozova D., Towards Big Data Analytics in the E-learning Space, Cybernetics and Information Technologies Vol. 19/3, 2019, ISSN: 1311-9702
137. Peneva V., Popchev I., Fuzzy Multi-criteria decision making algorithms, Comptes Rendus de l'Academie bulgare des Sciences Vol. 63, №7, 2010, 979-992, ISSN: 1310-1331
138. <https://balip.com/>
139. Toskova A., Toskov B., Doukovska L., Daskalov B. and Radeva I., “Neural Networks in the Intelligent Education Space”, ANNA'18; Advances in Neural Networks and Applications 2018, St Konstantin and Elena Resort, Bulgaria, 2018, pp. 107-112, IEEE Xplore Digital Library, VDE, Print ISBN: 978-3-8007-4756-6

БЛАГОДАРНОСТИ

Бих искал да изразя своите благодарности към научния си ръководител Академик Иван Попчев и ръководителя на секция Интелигентни системи при Институт по Информационни и Комуникационни Технологии – БАН, Професор д. н. Любка Дуковска за тяхната подкрепа, съвети, съпричастност и мотивация през годините.