

# **БЪЛГАРСКА АКАДЕМИЯ НА НАУКИТЕ**

**Институт по Информационни и Комуникационни Технологии**

---

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

### **АВТОРЕФЕРАТ**

**За присъждане на образователна и научна степен**

**“ДОКТОР”**

*Научна област:* 4. ПРИРОДНИ НАУКИ, „МАТЕМАТИКА И  
ИНФОРМАТИКА“

*Професионално направление:* 4.6. „ИНФОРМАТИКА И КОМПЮТЪРНИ  
НАУКИ”

*Докторантска програма:* ПО НАУЧНА СПЕЦИАЛНОСТ 01.01.12  
„ИНФОРМАТИКА“

**Веселин Лазаров Шахпазов**

**Научен ръководител**

**Акад. Иван Попчев**

**София**

**2019**

Дисертационният труд е обсъден на заседание на секция „Интелигентни системи“ на Института по информационни и комуникационни технологии при БАН на 23.09.2019 г. и е насочен за защита в научна област: 4. ПРИРОДНИ НАУКИ, „МАТЕМАТИКА И ИНФОРМАТИКА“ ,  
Професионално направление: 4.6. „ИНФОРМАТИКА И КОМПЮТЪРНИ НАУКИ”,  
Докторантска програма: ПО НАУЧНА СПЕЦИАЛНОСТ 01.01.12 „ИНФОРМАТИКА “.

**Данни за дисертационния труд:**

- Брой страници: 148 страници
- Брой на фигурите: 21
- Брой на таблиците: 12
- Брой на използваните източници: 138
- Брой на публикациите на автора по темата на дисертационния труд: 6

## УВОД

Във времето са предлагани и използвани различни методи за прогнозиране на капиталовия пазар на основата на техническия анализ, фундаменталния анализ и на статистически 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 магнитуда на движенията му.

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 настоящата дисертация ще бъдат разгледани някои традиционни техники за прогнозиране на пазара на акции и други финансови инструменти, търгувани на капиталовия пазар, 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 на прогнозиране.

Измежду многобройните техники от полето на Изкуствения интелект, тази които най-добре се справят с несигурността са невронните мрежи. 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. Невронните мрежи се справят с проблеми като несигурност и риск, по-добре в сравнение с други техники на изкуствения интелект, тъй като работят добре с големи и непрецизни бази данни. За разлика от експертните системи и системите основани на правила, невронните мрежи не са толкова понятни и резултатите получени, чрез тяхното използване не могат да бъдат толкова лесно обяснени, което ги прави трудни за интерпретиране.

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 обширно, този труд ще се съсредоточи върху използването им за прогнозиране на пазара на акции (фондовия пазар) и по-точно, този в България.

Основната задача на дисертационния труд, дефинирана и в заглавието му е изследване на модели за прогнозиране на капиталов пазар с невронни мрежи. Следва формулирането на 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

В Глава I от Дисертацията са разгледани традиционните аналитични методи, използвани за прогнозиране на капиталовите пазари: Фундаментален анализ, Технически анализ, Прогнозиране на базата на динамични редове от данни, Хипотезата за ефективния пазар, Теория на Хаоса, както и Други техники за прогнозиране на капиталовите пазари.

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. Доскоро, официалните пазари бяха единствените места за търговия, но това бе променено с Директивата за пазарите на финансови инструменти, известна като MiFID 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.

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 препредава на следващите неврони от мрежата.

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 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 изтъргуван 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.

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 изтъргуваните 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 настроенята в специализирани социални мрежи.

Освен това в Глава първа се прави обзор на етапите на развитие на невронните мрежи и на използването на други техники от инструментариума на изкуствения интелект за прогнозиране на финансовите пазари.

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

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 входящия 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. Скритите 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).

Освен това в Глава 2 бе направен подробен исторически преглед на прилагането на Изкуствени невронни мрежи за прогнозиране на финансовите пазари и цените на акции. 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. Фигура 1 показва схематично това наблюдение.




Фигура 1: Резултат от разгледаните научни статии според техните автори

Сред използваните архитектури, определено се откроява тази на изкуствени невронни мрежи с разпространение на информацията на право / 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 2 показва разпределението по видове невронни мрежи в разгледаните изследвания.



Фигура 2: Използвани архитектури н ИНМ

Пазарите, обект на изследване, са друг критерии, 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 авторът е да се насочи, именно към тази ниша на неизследвани и слабо познати пазари като българския, представен от едно изследване. Фигура 3 показва разпределението по видове пазари на трудовете.



Фигура 3: Класификация на пазар обект на изследване

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.

Макар при ниско ликвидните и слабо развити пазари 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 прогнозират и такива пазари.



### 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

Тази глава започва с кратка историята на българският фондов пазар, описване на неговата структура и с обосноваване на определянето му като неликвиден и неразвит борсов пазар.

Данните използвани за експериментите, проведени в тази глава, 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.

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%.

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:

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

Където:

- $\eta$  – степента на обучение;
- $\delta$  - локалният градиент на грешката;
- $\alpha$  - коефициент за инерция;
- $\sigma_i$  – резултата на  $i$ -тия елемент.

Праговете се третират като тегла, както следва  $\sigma_i = -1$ . 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 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 се ползва 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 обратното разпространение на грешката все още има предимства при някои обстоятелства и е най-лесният алгоритъм за разбиране.

В процеса на обратното 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. 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. 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.

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. 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.

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 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). 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 разпределянето на сетовете от данни.

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

$$E(t) = \frac{1}{1 + e^{-t}} \quad (2)$$

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.

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:

$$RMS = \sqrt{\frac{\sum_{i=1}^n (\hat{\delta}_i - \delta_i)^2}{n}} \quad (3)$$

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.

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

Първоначалните резултати от изследването не са особено добри. Те показват една интересна тенденция, а именно, че мрежите, които използват всичките десет входящи параметъра 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 прогнозната 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 авторът. 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.

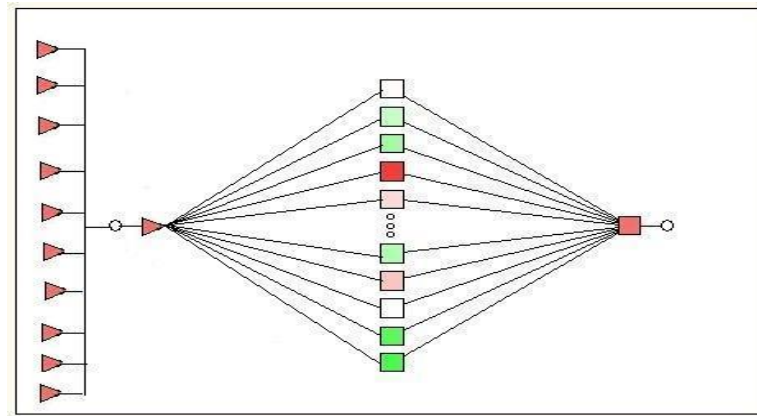
След като бяха взети предвид постигнатите първоначални резултати от които е видно, че трябва да се нанесат някакви корекции в модела, поради което авторът се насочи към входящите данни. Вземайки предвид особеностите на българския пазар на акции и по-специално неговата неликвидност, която позволява отделни сделки, не изпълнени на чисто пазарен принцип да влияят върху цялостната стойност и изменение на индекса бе сметено 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 1: Резултат след осредняване на дневните данни


Видно от резултатите в таблицата е, че извършеното осредняване дава резултат и успява да намали грешката при валидиращия сет от 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 и 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 времеемността 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 4



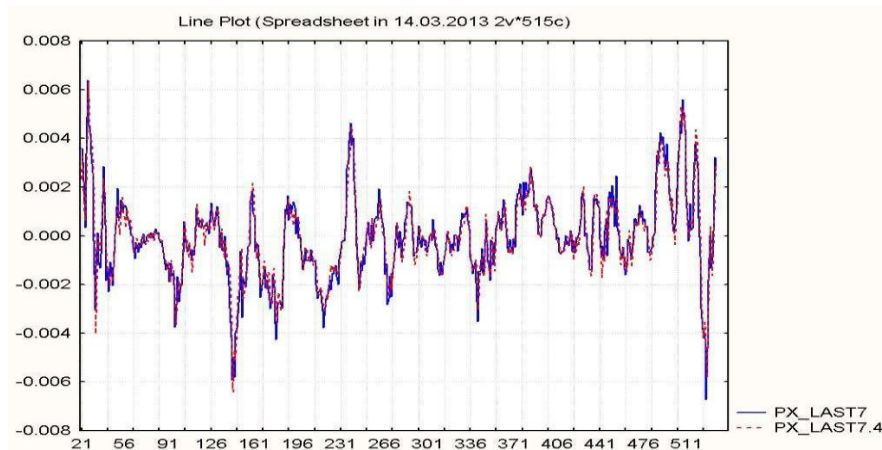
Фигура 4: Многослоен перцептрон с 10 входа, 13 неврона в скрития слой и един изходен елемент

На Фигура 5 са показани прогнозираните резултати спрямо действителните наблюдения на многослоен перцептрон с 10 входа, 13 неврона в скрития слой и един изходен елемент




Фигура 5: Диаграма на прогнозираните резултати спрямо действителните наблюдения.

Графика на прогнозираната стойност и на наблюдаваната в действителност е представена на следващата Фигура 6.



Фигура 6: 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 7.



Фигура 7: Диаграма на остатъчната грешка

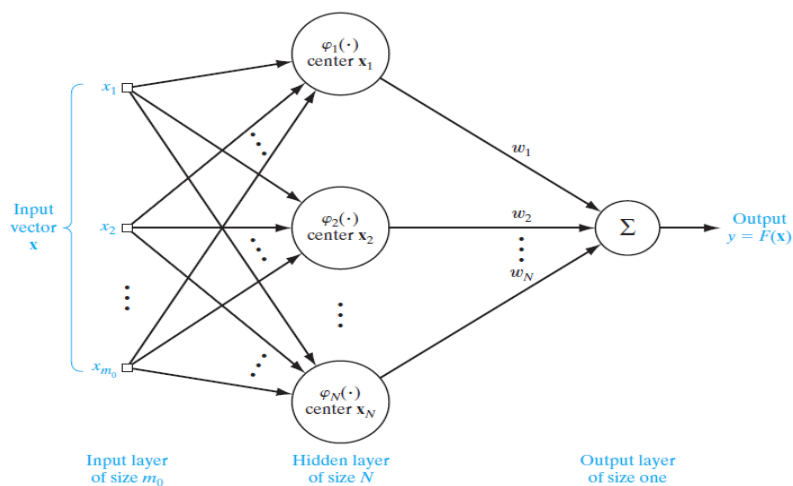
От графиката на остатъчната грешка, показана на Фигура 7 може да се види една интересна тенденция. В началото на периода и неговия край се наблюдава ръст на размера на грешката, който може да бъде обяснен със състава на входните данни, представени на изкуствената невронна мрежа. В първата част от наблюдавания 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 тренд 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.

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.

Експеримент върху два индекса на БФБ София с различни мрежови архитектури е представен в следващите редове.

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 8 е представен начин по който невронни мрежи с радиална базова функция се представят схематично.



Фигура 8: Невронна мрежа с радиална базова функция

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 многослойния 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.

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

$$y(i) = \sum_{j=1}^K w_j(n) \exp\left(-\frac{1}{2\sigma^2(n)} \|\mathbf{x}(i) - \boldsymbol{\mu}_j(n)\|^2\right), \quad i = 1, 2, \dots, n \quad (4)$$

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:

$$\mathfrak{E} = \frac{1}{2} \sum_{i=1}^n e^2(i) \quad (5)$$

Където:

$$e(i) = d(i) - y(i)$$

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, 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 на автора.

Третия тип мрежи, използвани в експеримента са 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, 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 многомерно пространство за измерване. Алгоритмичната форма може да се използва за всеки проблем с регресията, при който предположението за линейност не е оправдано.

Математическо представяне и схематичната форма на мрежите с обща регресия е показано на Фигура 9 отдолу:

$$\hat{Y}(\mathbf{X}) = \frac{\sum_{i=1}^m A^i \exp\left(-\frac{D_i^2}{2\sigma^2}\right)}{\sum_{i=1}^m B_i \exp\left(-\frac{D_i^2}{2\sigma^2}\right)} \quad (6)$$

$$\left\{ \begin{array}{l} A^i(k) = A^i(k-1) + Y^j \\ B^i(k) = B^i(k-1) + 1 \end{array} \right\} \quad (7)$$



Където:  $m$  е броя на клъстерите

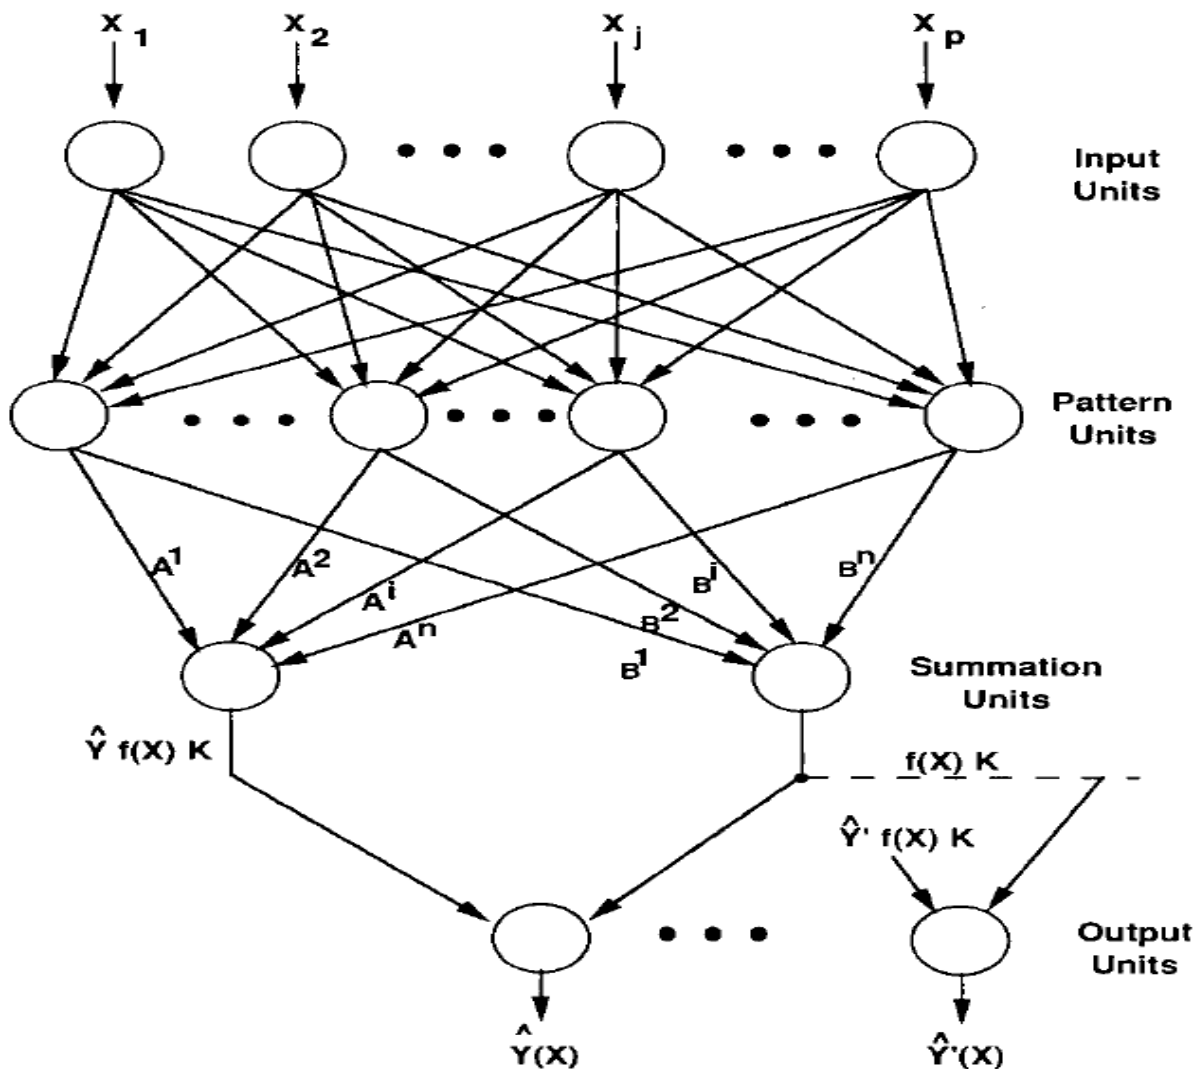
$A^i(k)$  и  $B^i(k)$  – са стойностите на коефициентите на клъстери  $i$  след  $k$  наблюдения

$A^i(k)$  е сумата на  $Y$  стойности

$B^i(k)$  е броя на шаблоните назначени за клъстер  $i$

$\sigma$  е вероятност за ширина

$$\hat{Y}(X) = \frac{\sum_{i=1}^m A^i \exp\left(-\frac{C_i}{\sigma}\right)}{\sum_{i=1}^m B^i \exp\left(-\frac{C_i}{\sigma}\right)} \quad (8)$$



Фигура 9: Изкуствена невронна мрежа с обща регресия

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

Сред недостатъците на изкуствените невронни мрежи с обща регресия са:

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

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.

Освен Sofix, 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.

Обект на експериментът отново ще бъде прогнозирането на стойностите на двата индекса в бъдещ момент, на база на предишна информация.

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 Sofix от по рано и желанието на автора да се правят по-малко предварителна обработка на данните.

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.

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 2 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 2: 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, 533 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. 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.

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 шестте изброени в Таблица 2 мрежи за избран период е показана на Фигура 10



Фигура 10: Графика на прогнозите за SOFIX на изкуствените невронни мрежи

На този етап, няма как да не бъдат отчетени някои изненадващи факти. На първо място са 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 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 3 са представени данните за грешките на шестте модела по време на обучението и при изпитващия сет от данни.

	<b>Neural network name</b>	<b>Training algorithm</b>	<b>Train Error</b>	<b>Select Error</b>
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 3: 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 са 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 11.

	<b>Neural network name</b>	<b>Training algorithm</b>	<b>Inputs</b>	<b>Hidden(1)</b>	<b>Hidden(2)</b>	<b>Test Error</b>
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 4: Прогнозиране на индекс BG40



Фигура 11: 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.

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 финансовите 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.

Представяне на хибриден модел изграден от невронни мрежи и системи базирани на правила, предназначен за търговия на БФБ – София.

Капиталовия 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.

Индексът Sofix 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 Sofix 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 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.

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.

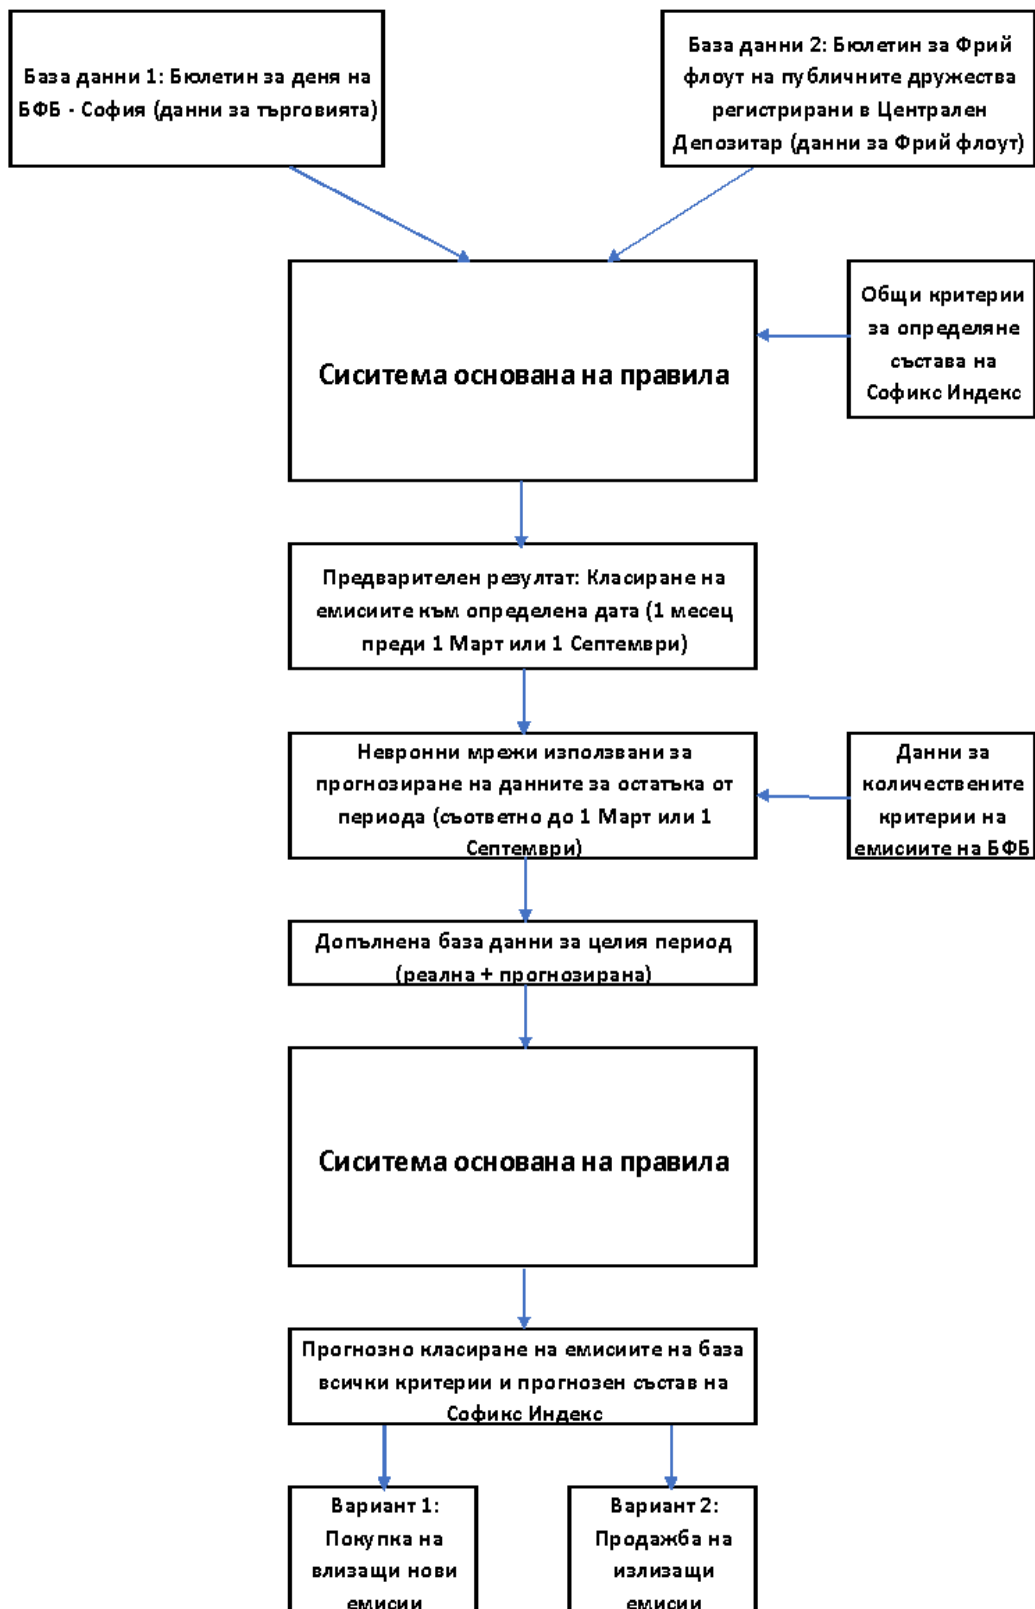
Информацията, с която е необходимо да се захрани модела е публично достъпна и се формира от дневния бюлетин, публикуван от БФБ – София, съдържащ цялата информация за дневната търговия на всички емисии ценни книжа, регистрирани за търговия, както и бюлетина за фрий флоута на търгуваните емисии, публикуван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

Системата основана на правила използват базирани на човешки опит знания за разрешаването на различни проблеми, които обикновено изискват човешки интелект за решаване. Тези знания се оформят като правила или данни в компютърни системи и програми. В зависимост от решавания проблем, системата може да използва тези знания. За целта те се съставят от т.нар. елемент за вземане на решения, който преценява кои от наличните знания да бъдат избрани и приложи, както и от прикрепени към него модули от знания и правила. Този елемент продуцира указания за действие, класификации и пр., като едно от предимствата му е, че те са прозрачни и могат да бъдат обосновани с програмираните правила и схеми на действие в модела или комбинации от тях. По този признак базираните на правила системи се различават от невронните мрежи, които често са определяни като черни кутии, резултатите от които е много трудно да бъдат обяснени.



На базата на разгледаните многобройни 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 прогнозират бъдещото развитие на основните 4 показателя на базата на които се съставя класирането на емисиите за състава на Sofix. Идеята е да бъдат направени 2 вида прогнози: Първи за един ден напред на базата на първоначално наличната информация за целия оставаш период и втори, да бъдат формирани динамични данни, като резултатите за всеки следващ ден напред, продуцирани от мрежите бъдат включени в данните за обучение.

Схематично, хибриден модел изграден от невронни мрежи и системи базирани на правила, предназначен за търговия на БФБ – София е представена на Фигура 12.



Фигура 12: Хибриден модел изграден от невронни мрежи и системи основани на правила

Както се вижда 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 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 основана 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.

## 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) 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

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 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 изпитващите данни 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 ѝ 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 счестени 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 предложението от автора хибриден модел от невронни мрежи и системи основани на правила, предназначен за търговия на БФБ – София. Моделът се смята за 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, марджин покупки и липсата на деривативни инструменти) и липса на много на брой качествени емитенти с които може да се характеризира българския борсов пазар.

В резултат от проведените изследвания представени в настоящия дисертационен труд, са постигнати определени 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 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 изглеждат да справят много по-добре в моделирането на данните на входовете си, като успяват да продуцират еднакво добри резултати независимо от различен брой входящи параметри. Например една от най-добрите представени мрежи 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.



## ГЛАВА VI: ПУБЛИКАЦИИ ПО ТЕМАТА НА ДИСЕРТАЦИЯТА И ЦИТИРАНИЯ

Публикации по темата на дисертационния труд:

Shahpazov V., Doukovska L., Karastoyanov D., 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, SCITEPRESS – Science and Technology Publications, 2014, ISBN: 978-989-758-032-1, DOI:10.5220/0005427202820288, 282 – 288.

Shahpazov V., Doukovska, 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.

Shahpazov V., Velev 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, SCITEPRESS – Science and Technology Publications, 2013, ISBN:978-989-8565-56-3, DOI:10.5220/0005427202820288, 298-303.

Shahpazov V., Velev V., Doukovska L., “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, IEEEExplore, 2013, ISBN:978-1-4673-6319-8-13, CD Proc.

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, Международна Научна Конференция „Изкуствен Интелект и Е-Лидерство“, Пловдив, Октомври 2019 г. (под печат)

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 (ICCUBEA), DOI 10.1109/ ICCUBEA.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. 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.

## **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.