

СТОПАНСКА АКАДЕМИЯ “Д. А. ЦЕНОВ” – СВИЩОВ
КАТЕДРА “ФИНАНСИ И КРЕДИТ”

АНТОНИО ВАЛЕНТИНОВ ДИЧЕВ

**ОЦЕНКА НА ФИНАНСОВИЯ РИСК
ПОСРЕДСТВОМ МАШИННО ОБУЧЕНИЕ**

АВТОРЕФЕРАТ

**НА ДИСЕРТАЦИЯ ЗА ПРИСЪЖДАНЕ НА ОБРАЗОВАТЕЛНА И
НАУЧНА СТЕПЕН “ДОКТОР” ПО ДОКТОРСКА ПРОГРАМА
“ФИНАНСИ, ПАРИЧНО ОБРЪЩЕНИЕ, КРЕДИТ И ЗАСТРАХОВКА”**

*Научен ръководител:
Доц. д-р Александър Петров Ганчев
Доц. д-р Красимира Борисова Славева*

**Свищов
2025 г.**

Дисертационният труд е обсъден и насочен за защита по реда на Закона за развитие на академичния състав от катедра „Финанси и кредит” на Стопанска академия „Димитър А. Ценов” – Свищов на заседание, проведено на 03.12.2025 г.

Дисертационната разработка има общ обем от 197 стандартни страници и съдържа: въведение – 9 страници, основен текст, поместен в три глави – 154 страници, заключение – 4 страници, списък на цитираните и използвани литературни източници – 120 броя и декларация за оригиналност. Дисертационният труд е илюстриран с 34 фигури, 43 таблици и 26 уравнения.

Откритото заседание на научното жури за защита на дисертационния труд ще се състои на 16.03.2026 г. от 13:30 часа в Заседателна зала „Ректорат“ на Стопанска академия „Димитър А. Ценов” – Свищов.

Материалите по защитата са на разположение на интересуващите се в Отдел „Докторантура и академично развитие“ на Стопанска академия „Димитър А. Ценов” – Свищов.

I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

1. АКТУАЛНОСТ НА ТЕМАТА

Актуалността на анализирания в дисертационния труд проблем е сериозно подхранена от експоненциално нарастващата дигитализация във всички сфери през последните години, която води до ръст на количеството данни с възможност за изследване и анализ. Именно данните и техният анализ, като основа за вземане на решения и управление, са изключително ценни във финансовия свят. В малко по-тесен смисъл и от своя страна оценката и управлението на риска във финансите е област, която се опитва да използва в максимална степен и по обективен начин наличните данни и информация. С висока степен на значимост се отличават технологиите на изкуствения интелект (вкл. машинното обучение), които при анализа на големи масиви от данни биха могли да спомогнат за откриването на по-трудно забележими зависимости в процеса по създаване на модели за оценка на риска.

2. ОБЕКТ И ПРЕДМЕТ НА ИЗСЛЕДВАНЕТО

За **обект** на дисертационния труд се определя финансовият риск.

Предмет на изследването са конкретните алгоритми, инструменти и методи от машинното обучение, които могат да бъдат използвани за количествено моделиране и изграждане на ефективни инструменти за оценка на основните видове финансов риск – кредитен, пазарен и операционен.

3. ЦЕЛИ И ЗАДАЧИ НА ИЗСЛЕДВАНЕТО

Цел на изследването е разкриването на потенциална добавена стойност от прилагането на машинното обучение като инструмент за оценка на отделните видове финансов риск. Подходът за селекция на алгоритми и методи се основава на сравнение между две семейства от алгоритми – т.нар. традиционно установени (класически) методи за оценка на финансовия риск и алгоритми, основаващи се на машинно обучение.

Задачите, върху които настоящата работа се фокусира, са, както следва:

- да се изведат основните категории финансов риск с най-голяма същественост и потенциал за добавена стойност на машинното обучение като инструмент за количествена оценка;

- да се разграничат посредством прозрачен и обоснован подход методите, които са разпознати като такива с машинно обучение, и такива, които секторът на финансови услуги използва традиционно при оценката на риска;

- да се проследи регулаторната рамка относно прилагането на алгоритми, използващи изкуствен интелект и машинно обучение при финансовия риск мениджмънт;

- да се извърши подбор на методи за оценка на финансовия риск, които са представители от групата на машинното обучение, и такива, които са представители на класическите;

- да се проучат и изведат основните и подходящи количествени показатели и критерии за оценка и анализ на представянето при различните алгоритми и методи;

- да се приложат по подходящ подход подобрите алгоритми за оценка на риска, по начин и в среда, които авторът, установената практика и прегледът на литературата са открили като такива с най-висок потенциал;

- да се направи задълбочено, базирано на сравними извадки от данни и по подходящ начин сравнение на представянето при различните групи методи за оценка на риска.

4. МЕТОДОЛОГИЯ НА ИЗСЛЕДВАНЕТО

Методологията, която се използва в дисертационния труд, включва методите на теоретичен анализ и синтез, сравнителен анализ, моделиране на риска посредством традиционни методи и посредством машинно обучение, валидационен анализ на база статистически тестове и методи, SHapley Additive exPlanations (SHAP) анализ и други.

5. ИЗСЛЕДОВАТЕЛСКА ТЕЗА

Тезата, която се отстоява в дисертационния труд, е, че прилагането на методи от машинното обучение може съществено да подобри оценката на финансовия риск чрез по-лесно откриване на иначе скрити зависимости и интеракции, автоматизирана обработка на големи обеми данни, включително способност за бърза адаптация към динамично променящите се условия.

6. ОГРАНИЧИТЕЛНИ УСЛОВИЯ

Основните **ограничителни условия**, при които се извършва настоящата дисертационна разработка, са свързани с факта, че анализът се концентрира върху конкретни извадки от данни, ограничен набор от

алгоритми и само върху някои категории финансов риск (кредитен, операционен и пазарен риск).

Ограниченията по-горе произтичат от съображения на автора, тъй като покриването на пълния набор от типове риск, техните проявления, алгоритми и извадки от данни е задача, която би поставила разработката в ситуация с практическа невъзможност. Поради тези съображения **извън обхвата** на разработката остават редица алгоритми и методи, останалите разновидности на финансовия риск, други показатели и аспекти от анализирания типове риск.

7. ПРАКТИЧЕСКА ПРИЛОЖИМОСТ

Развитите в дисертационния труд теоретични разсъждения и изводи, както и получените емпирични резултати от изследването, имат за цел да подкрепят решенията при изграждане на ефективна рамка за управление на финансовия риск. Изложеният комплекс от методология и технически похвати е концентрирано насочен към практическата полза от тяхното прилагане. В допълнение, пълният инструментариум е приложен върху извадки от данни, които наподобяват в много висока степен практиката в тази област.

Към трета глава от дисертационния труд са изведени редица практически аспекти при използването на всеки един от изградените модели – области, в които се прилагат, и тяхната важност. Подборът на моделираните риск показатели и аспекти се базира изцяло на съображения от практически характер. Тоест, подобрите области за изграждане на модели и последващата им оценка са сред най-материалните и значими в сектора на финансови услуги.

Фокусът на разработката е насочен именно към оценката на практическата полза от внедряването на методи с по-високи изисквания и

инвестиции. Изследването разглежда проблеми от практиката, като злоупотреба със съдържанието на термина изкуствен интелект (т.нар. AI washing), и се опитва да систематизира методология, посредством която би могло да бъдат изведени ползите и недостатъците от имплементацията на един по-сложен комплекс от методология за оценка на риска.

Практическата приложимост на разработката е допълнително подкрепена от прегледа и интегрирането на регулаторните очаквания в областта. Подходът за извършения валидационен и сравнителен анализ е до голяма степен базиран на регулаторните виждания за оценка на представянето при изграждането на риск модели.

II. СТРУКТУРА И СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

Дисертационният труд е разработен при спазване на изискванията на чл. 27, ал. 2 от Правилника за прилагане на Закона за развитие на академичния състав в Република България. Той има общ обем от 197 стандартни страници и в структурно отношение включва:

Първо. Въведение от 9 стандартни страници.

Второ. Основен текст, съставен от три глави с общ обем от 154 стандартни страници.

Трето. Заключение с обем от 4 стандартни страници.

Четвърто. Списък от 120 използвани литературни и интернет източници, като от всички източници 113 са на английски език, а 7 са на български език.

Пето. Дисертационният труд е илюстриран с 34 фигури, 43 таблици и 26 уравнения.

Шесто. Декларация за оригиналност съгласно чл. 68 ал. 2 от Правилника за развитието на академичния състав в СА „Д. А. Ценов“

Във въведението на дисертационната разработка се очертават основните аспекти на нейната актуалност и се дефинират основните ѝ научни реквизити – обект, предмет, цел, задачи, теза, методология и ограничителни условия. В първата глава на дисертационния труд се изследват теоретичните основи при основните категории риск, историческото развитие на машинното обучение, неговата дефиниция и регулаторните очаквания върху машинното обучение. Във втората глава от дисертационния труд фокусът се поставя върху методологията – систематизиране на конкретни показатели за оценка на риска, тяхното моделиране посредством машинно обучение и класически подходи, както и методология за количествен валидационен анализ на моделите. В трета

глава на дисертацията фокусът попада върху практическите аспекти от прилагането на машинното обучение. Анализирани и проследени са т.нар. AI washing (AIW), а изведените показатели за оценка на риска от втора глава са моделирани посредством стандартни методи и алгоритми за машинното обучение. В допълнение, е направен сравнителен анализ между двата основни подхода за моделиране и представянето при отделните показатели за оценка на риска.

В конкретен план съдържането на дисертацията включва следните основни части:

СЪДЪРЖАНИЕ

ВЪВЕДЕНИЕ

ГЛАВА ПЪРВА. ТЕОРЕТИЧНИ ОСНОВИ И КОНЦЕПЦИИ ЗА ФИНАНСОВИЯ РИСК И МАШИННОТО ОБУЧЕНИЕ

1. Същност, теоретични аспекти и видове риск
 - 1.1. Характеристики при пазарния риск
 - 1.2. Основни аспекти и същност на кредитния риск
 - 1.3. Финансова дефиниция на ликвидния риск
 - 1.4. Операционен, правен и регулаторен риск - финансова дефиниция и проявление
 - 1.5. Бизнес моделът и бизнес взаимоотношенията в обхвата на финансовия риск мениджмънт (бизнес риск)
 - 1.6. Стратегическите решения – проявление и значение за финансовия риск
 - 1.7. Репутацията – източник на финансов риск
 - 1.8. ESG факторите като форма на финансов риск
2. Систематика и анализ на концепциите за машинното обучение при оценката на финансовия риск

- 2.1. Ключови моменти в историята от развитието на машинното обучение и изкуствения интелект
3. Изследвания, свързани с ML при оценката на финансовия риск
4. Машинното обучение и регулаторната рамка в Европейския съюз
 - 4.1. Законова рамка на Европейския съюз (AI act)
 - 4.2. Машинното обучение във фокуса на Европейския банков орган (ЕБО)
 - 4.3. Машинното обучение като техника за вътрешнобанков модел и определяне на капиталови изисквания (ECB guide to internal models, release number 4.0)

Изводи от глава първа

ГЛАВА ВТОРА. МЕТОДОЛОГИЧЕСКИ АСПЕКТИ НА ОЦЕНКАТА НА ФИНАНСОВИЯ РИСК ЧРЕЗ КЛАСИЧЕСКИ ИНСТРУМЕНТИ И МАШИННО ОБУЧЕНИЕ

1. Ключови количествени показатели за кредитен, пазарен и операционен риск
2. Оценка на риска посредством традиционни алгоритми и методи
 - 2.1. Проблеми от класификационен тип
 - 2.2. Анализ на времеви редове (time series)
3. Оценка на риска посредством методи на машинното обучение
 - 3.1. Проблеми от класификационен тип
 - 3.2. Анализ на времеви редове (time series)
 - 3.3. Анализ на настроенията и тона в текст (Sentiment analysis)
4. Количествени методи за оценка и валидация на модела
 - 4.1. Оценка на дискриминационната способност (Somers'D / AUC)
 - 4.2. Консервативност на оценките (Binomial test)
 - 4.3. Други метрики за оценка на класификационен алгоритъм (confusion matrix)
 - 4.4. Средноквадратична грешка (Root Mean Square Error, RMSE)
 - 4.5. Коефициент на детерминация (R^2)
 - 4.6. SHAP (SHapley Additive exPlanations)

Изводи от глава втора

ГЛАВА ТРЕТА. ПРАКТИЧЕСКИ АСПЕКТИ ПРИ КОЛИЧЕСТВЕНАТА ОЦЕНКА НА ФИНАНСОВИЯ РИСК. СРАВНИТЕЛЕН АНАЛИЗ НА ПРЕДСТАВЯНЕТО МЕЖДУ КЛАСИЧЕСКИ И MACHINE LEARNING МЕТОДИ

1. Между маркетинг и реалност – феноменът „AI изпиране“ (AI washing, AIW)
2. Моделиране на вероятността от неизпълнение (Probability of default, PD) при управлението на кредитния риск
3. Моделиране на показателя стойност под риск (Value-at-Risk, VaR)
4. Изграждане на модел за идентифициране на измами при картови трансакции като инструмент за управление на операционния риск
5. ESG рискове – моделиране на ESG рейтинг за компаниите от борсовия индекс S&P 500

Изводи от глава трета

ЗАКЛЮЧЕНИЕ

ПРИЛОЖЕНИЕ

БИБЛИОГРАФИЯ

ДЕКЛАРАЦИЯ ЗА ОРИГИНАЛНОСТ

III. КРАТКО ИЗЛОЖЕНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

ВЪВЕДЕНИЕ

Въведението подчертава двата основни стълба на анализ, около които се развива дисертационният труд – оценката на финансовия риск и използването на машинно обучение за моделиране на риска. Въведението разглежда възможността за интеграция между риск мениджмънт и машинно обучение, поставяйки акцент върху тяхната актуалност, важност и необходимост от непрекъснато усъвършенстване. Формулирани са ключовите научни реквизити: обектът, предметът, основните цели и задачи на дисертационния труд. Дефинирана е защитаваната теза, основните ограничителни условия и прилаганата методология в изследването. Описана е структурата и съдържанието на отделните части в дисертацията.

ГЛАВА I. ТЕОРЕТИЧНИ ОСНОВИ И КОНЦЕПЦИИ ЗА ФИНАНСОВИЯ РИСК И МАШИННОТО ОБУЧЕНИЕ

Глава I изгражда фундаменталната и от гледна точка на теорията основа на изследването. Направен е преглед на основните видове финансов риск и дефиницията за машинно обучение (machine learning, ML), около която се изгражда дисертационното изследване. Систематизирани и проучени са актуалните изследвания по темата за машинно обучение и неговата роля за оценка на риска. Обърнато е внимание на регулаторната рамка по отношение на изкуствения интелект и машинното обучение като инструмент за оценка на риска.

Главата започва с дефиниция и систематизация на отделните категории финансов риск от гледна точка на теорията и практиката в банковия сектор – пазарен, кредитен, операционен, ликвиден, стратегически, бизнес и стратегически риск. Обръща се специално внимание и на ESG (Environmental, Social, and Governance) факторите, тяхната същност и проявление като източник на финансов риск.

При изграждането на дефиниция за машинното обучение, за целите на настоящото изследване и неговия обект, авторът разглежда както литературата, така и разбирането на практиката и регулаторите по темата. Проследено и систематизирано е историческото развитие на машинното обучение, което помага съществено при изграждането на дефиниция за модерното разбиране на машинно обучение и съдържанието, което се влага от практиката през последните години. В регулаторен план, и от гледна точка на практиката като цяло, влаганият смисъл в понятието за машинно обучение не се разминава по същество и разбиране, но се очертава и възприема един по-тесен обхват. Именно тази дефиниция е приложена и от автора в дисертационния труд.

Въпреки че съществуват редица изследвания, посветени на използването на машинното обучение за оценка на риска, много от тях не разполагат с теоретична рамка, която да проследява еволюцията на алгоритмите, или не акцентират върху ключовите различия между тях. Освен това практическите аспекти често се пренебрегват. Показателен пример от някои случаи е използването на метрики за оценка на ефективността, които не са подходящи при небалансирани извадки от данни. От прегледа на литературни източници прави впечатление, че преобладават изследванията, свързани с оценка на кредитния и пазарния риск. През последните години се обръща по-съществено внимание и на теми като риск от загуба на приходи и клиенти и анализ на естествен език.

Изследването се опитва да преодолее тези пропуски, като предоставя теоретична перспектива върху еволюцията на алгоритмите, подчертава практическите аспекти и използва по-подходящи показатели за оценка на представянето при различните алгоритми. И от друга страна, подлага на критичен анализ демонстрираните резултати през призмата на реалното количество добавена стойност и необходимия ресурс при тяхното изграждане и внедряване.

Последната част от главата разглежда нормативния контекст, в който финансовите институции следва да внедряват ML. Този преглед на съществуващите норми и документи обхваща най-важните регулаторни стъпки в тази посока. Сред тях най-голямо впечатление прави т.нар. Закон за изкуствения интелект в Европейския съюз (Artificial Intelligence Act, AI Act), принципите и насоките на Европейската централна банка (ЕЦБ) относно изграждането на модели за управление на риска, които използват машинно обучение и изкуствен интелект като цяло. С изграждане на принципи и насоки на по-високо управленско ниво се открояват и множеството документи на Европейския банков орган (ЕБО), които поставят акцент върху интерпретируемостта, моделното управление и управленската отговорност.

От работата по първа глава впечатление прави, че материализирани форми на финансова нестабилност, фалити и други водят до последващи мерки, поуки и преосмисляне на практиката. Често зад тези събития стои недобре оценен и/или управляван финансов риск. Оценката на риска, от своя страна, е с категорично и подчертано значение. Обичайно тази задача използва математически и статистически методи и техники. Те имат своето исторически доказано място и добавена стойност. В последните години обаче еуфорията около изкуствения интелект и машинното обучение повдига въпроси, свързани с приложението им почти във всички сфери.

Подчертава се, че ML може да подобри надеждността на вътрешните модели, но изисква строга валидация, документация и етична употреба.

От историческия преглед, свързан с развитието на изкуствения интелект, се установи, че методите, класифицирани като машинно обучение, не възникват през последните 5, 10 и дори 20 години. През последните години се наблюдава тяхното надграждане, усложняване и имплементиране. Всъщност би могло да се твърди, че наличието на достъпни и мощни изчислителни ресурси захранва бурното развитие напоследък. Този прочит и виждане обичайно остават извън ползрението на мениджъри, финансови директори и управителни органи. Именно поради това авторът предлага едно не толкова теоретично разделение между технологиите (класически и основани на машинно обучение), а по-скоро ориентирано към пазарното разбиране. Този поглед е подкрепен и от прегледа на регулаторната рамка при банковия сектор в Европа. От нейния преглед стана ясно, че машинното обучение е тема с нарастващ интерес сред регулаторните органи. В по-широк смисъл, не само за сектора на финансови услуги, са поставени основите и на Закон за изкуствения интелект в Европа. Тези процеси ясно засвидетелстват важността на темата и очакванията за тази важност в бъдеще.

ГЛАВА II. МЕТОДОЛОГИЧЕСКИ АСПЕКТИ НА ОЦЕНКАТА НА ФИНАНСОВИЯ РИСК ЧРЕЗ КЛАСИЧЕСКИ ИНСТРУМЕНТИ И МАШИННО ОБУЧЕНИЕ

Глава втора представя методологичната рамка за оценка на финансовия риск чрез интегриране на класически статистически методи и съвременни техники на машинното обучение. В началото са

систематизирани ключовите количествени показатели, използвани при анализа на кредитен, пазарен и операционен риск. Разглеждат се основни регулаторни и аналитични метрики като вероятност за неизпълнение, загуба при неизпълнение, стойност под риск и други. Този преглед създава аналитична основа, която позволява сравнение между традиционните и базираните на машинно обучение подходи.

Методологическият преглед откри основните видове риск, заедно със съответстващите им показатели, които биват оценявани и използвани в ежедневните операции на финансовите институции. В зависимост от естеството на тези показатели се използват и прилагат различни инструменти за моделиране. Очертаната граница между класически методи и такива на машинно обучение в Глава първа предоставя основа за избор на съответстващите им представители. Палитрата от алгоритми и при двете групи е много голяма, а изборът следва да се сведе до няколко конкретни представители, посредством които би могло да се изпълнят поставените задачи на настоящата работа. Тази задача е подпомогната от авторитетни проучвания и данни в комбинация с избора на ключови риск показатели за оценка. Именно по този начин са идентифицирани количествени методи, които авторът в Глава трета ще приложи, а впоследствие сравни тяхното представяне.

Към семейството на традиционните методи за моделиране на риска за проблеми от класификационен характер е припозната логистичната регресия. В допълнение към този регресионен анализ и като негова основа е приложен подходът на групиране при независимите променливи и т.нар. Weight of evidence (WoE) трансформация, вкл. изчисляване на индикатора Information Value (IV). Този подход за моделиране е широко прилаган и утвърден в практиката. В отделен фокус са представени и методи за анализ на времеви редове, приложими при прогнозиране на пазарни движения и волатилност, като Generalized Autoregressive Conditional Heteroskedasticity (GARCH).

В следващата част на главата се представят методите на машинното обучение като съвременна алтернатива на класическите модели. Анализират се алгоритми, ориентирани към класификация – дървета на решенията, вкл. ансамблови методи като Gradient Boosting и eXtreme Gradient Boosting (XGBoost). Използваният метод от областта на машинното обучение за анализ на времеви редове е т.нар. DeepAR, който е базиран на авторегресионна рекурентна изкуствена невронна мрежа (Recurrent neural network, RNN).

Отделено е внимание и на анализа на настроенятия като метод за извличане на информация от текстови източници. Анализ на настроенятия (sentiment analysis), известен още като извличане на мнения (opinion mining), е ключова техника в обработката на естествен език (Neuro Linguistic Programming, NLP), която включва идентифициране и извличане на субективна информация от текстови данни. Този процес е от съществено значение за разбирането на емоционалния тон зад съответния текст, което може да предостави ценни прозрения в различни области като маркетинг, наблюдение на социални медии, анализ на обратна връзка от клиенти и финансови пазари. Представени са NLP техники: Valence Aware Dictionary and sEntiment Reasoner (VADER), Financial Bidirectional Encoder Representations (FinBERT) и Generative Pre-trained Transformer 2 (GPT-2), които позволяват използването на новинарски потоци при оценката на рисковете, произтичащи от ESG факторите.

В машинното обучение съществуват т.нар. хиперпараметри. Това са настройки на конкретния алгоритъм, които не се “научават” от самите данни и които определят поведението и колко сложна да бъде архитектурата на модела. Тоест, дори при използването на един и същи алгоритъм (напр. XGBoost) е съвсем нормално при различни извадки от данни да има различна архитектура и сложност на финалния модел. До финалните стойности на хиперпараметрите се достига посредством процес по търсене на техните най-оптимални такива. Това е съществена и ключова

стъпка от цялостния процес по прилагане на ML алгоритми. В най-общ смисъл правилото е да се избере тази комбинация от стойности на настройките, която води да най-добри финални резултати. Разгледани са различни подходи за търсене на оптималните стойности, но сред най-широко прилаганите са ръчна настройка, “Grid Search” и „Random Search“.

Анализът на методологията подчертава предимствата на методите за оценка на риска, базирани на машинно обучение, които спомагат обработката на големи обеми данни и предлагат иновативни подходи. Тези алгоритми обаче се отличават и със съществено по-комплексен и интензивен набор от изчисления. А това от своя страна създава допълнителни предизвикателства.

Заклучителната част на главата разглежда количествените методи за валидиране и оценка на моделите. Подборът на методи и показатели е извършен в съответствие с утвърдените практики за оценка на модели, прилагани в научната литература и в банковата и надзорната практика. Избраните техники представляват стандартни бенчмаркове за оценяване на прогнозната ефективност, като същевременно имат значение и при процесите по валидиране и одобрение на модели за капиталови цели. Този подход осигурява възможност за обективно сравнение между различните алгоритми и за преценка на тяхната приложимост в контекста на управлението на финансовия риск.

Представени са показатели за дискриминационна способност като Somers' D и Area Under the Curve (AUC), които измерват точността на класификационните модели. При различните типове модели изискваната и очаквано минимално ниво на дискриминационна способност е различно. Предвид това, че в настоящата разработка и в контекста на този измерител акцентът е основно върху това, дали и с колко ML методите допринасят за по-висока дискриминационна способност, разглеждаме изменението на показателя спрямо традиционните алгоритми (логистична регресия).

Обсъдени са и подходите за оценка на консервативността чрез биномен тест, както и традиционни метрики, свързани с матрицата на объркване (confusion matrix). Тя представлява стандартен инструмент в оценката на модели за класификация. Матрицата позволява по-детайлен анализ на грешките, отколкото просто показването на обща точност (accuracy), поради което е особено полезна при неравномерно разпределени класове или при случаи, където отделни видове грешки имат различна тежест. Приложението и тълкуването на тези показатели следва да бъде извършвано в контекста на конкретните задачи и проблеми – според значението и ”тежестта” на различните типове грешки. Например в областта на медицината и диагностиката откриването на класа със заболяване (True Positive Rate, TPR) е съществено по-важен аспект от прецизността (Precision). Не такъв може да е случаят обаче с фалшивите новини например.

За модели, които прогнозират непрекъснати променливи, т.е. регресионни модели, са припознати показателите средноквадратична грешка (RMSE) и коефициентът на детерминация (R^2).

Кои характеристики, с каква тежест и как определят прогнозите на даден модел, може да бъде изключително важно, понякога на съпоставимо ниво и с прецизността на модела. Често с най-висока точност при големи извадки от данни се открояват сложни модели, като ансамблови или дълбоки невронни мрежи, които дори тесните експерти трудно могат да интерпретират. Това създава известна дискусия около добавената им стойност и предполага търсенето на баланс между точност и интерпретируемост. В практиката по-скоро се налага и припознава едно решение, което предоставя унифицирана рамка за интерпретиране на резултатите от даден модел — SHAP.

Оценката за прецизността и представянето на алгоритмите като цяло, обичайно, в банковия сектор е известно като валидационен анализ на моделите (валидация). Този процес представлява изключително мащабна

и всеобхватна дейност, която се старее да подсигури надеждно и информирано използване на моделите. Дотолкова важен е този аспект, че ЕЦБ и други регулатори имат много съществен минимум от практики, принципи и количествени методи за извършване на тези дейности. За да се сравни представянето на двете семейства от алгоритми, настоящата разработка прилага именно част от тези насоки и принципи.

Посредством прилагането на статистически и количествени анализи се цели да се установи доколко конкретният модел предоставя адекватна и надеждна оценка. Постановката в настоящия дисертационен труд би могла да упражни и приложи част от установената практика и регулаторни изисквания. Това от своя страна се дължи на множеството допълнителни условия, които възникват едва когато един модел е в т.нар. ”продукционна среда” и предоставя решения в реално време с динамични данни и процеси. Подбраните методи обаче са сред ключовите показатели, които в практиката са обект на мониторинг и контрол. За да е максимално ориентирана към практиката, в настоящата разработка се прилагат, анализират и последващо оценят моделите именно посредством тези показатели за валидация.

В обобщение главата изгражда последователна методологична основа, която съчетава класическите количествени подходи с модерни техники на машинното обучение и предлага цялостна рамка за оценка, валидация и интерпретация на моделите за финансов риск. Тази основа служи като фундамент за емпиричните анализи и приложените модели, разработени в следващите части на изследването.

ГЛАВА III. ПРАКТИЧЕСКИ АСПЕКТИ ПРИ КОЛИЧЕСТВЕНАТА ОЦЕНКА НА ФИНАНСОВИЯ РИСК. СРАВНИТЕЛЕН АНАЛИЗ НА

ПРЕДСТАВЯНЕТО МЕЖДУ КЛАСИЧЕСКИ И MACHINE LEARNING МЕТОДИ

Глава трета е посветена на изграждането (моделирането) на модели за оценка на финансовия риск чрез класически статистически подходи и съвременни методи на машинното обучение. На база резултатите от отделните методи и алгоритми е произведен сравнителен анализ между тях. Основният акцент е поставен върху реалното представяне на моделите, разграничаването между маркетингови твърдения и действителна ефективност, както и върху необходимостта от критично отношение към т.нар. феномен „AI изпиране“, при който технологиите с ниска добавена стойност се представят като авангардни ML решения. Като всяка друга еуфория и пазарно доминиране, методите на машинното обучение създават и своите проблеми. Обичайно тези проблеми са обвързани основно с недобро разбиране на технологията, затруднение при оценката на фактическата добавена стойност, по-бавно развитие на регулаторната рамка и не на последно място липсата на консенсус около дефиницията за изкуствен интелект. В този контекст главата очертава рамките, в които машинното обучение наистина допринася за по-добро управление на риска и случаите, при които класическите методи продължават да превъзхождат или да бъдат предпочитани.

С цел постигане на реално приложими и мащабируеми резултати настоящата разработка се фокусира върху няколко ключови аспекта на управлението на риска, които позволяват количествено моделиране и последващ емпиричен анализ. Подборът на тези направления е резултат от предварително изследване на релевантните практики и научни разработки в областта на финансовия риск мениджмънт. Въз основа на този преглед са идентифицирани четири основни категории риск, които притежават най-съществен потенциал за анализ чрез методите на машинното обучение

– кредитен риск, пазарен риск, операционен риск (в частност риск от измама) и ESG риск.

Предприетият подход е целенасочено фокусиран върху прагматичния аспект – за всяка от тези области е избрана конкретна характеристика, която може да бъде количествено измерима, подлежаща на моделиране и сравнителен анализ. Това позволява не само теоретично обосноваване, но и практическа демонстрация на приложимостта на различни алгоритми за машинно обучение при управление на риска.

Съществена част от анализа е посветена на моделирането на вероятността от неизпълнение, където моделите се разглеждат паралелно през призмата на логистичната регресия (като традиционен и регулаторно признат метод) и алгоритми на машинното обучение (като Gradient Boosting и XGBoost). Изследват се техните дискриминационни способности, интерпретируемост, т.нар. confusion matrix и други. Правят се изводи относно значимостта и приложимостта им в кредитния риск.

В следващата част се анализира моделирането на стойност под риск (VaR) чрез сравнение между класическите подходи, базирани на GARCH модела, спрямо машинно-базирани техники, които използват невронни архитектури (DeepAR). Разгледано е доколко ML може да подобри прогнозната точност на VaR и в кои случаи по-сложната архитектура и имплементация на методи с машинно обучение не води до добавена стойност.

Допълнително е изследвано изграждането на модели за откриване на измами при картови трансакции като представителен пример за управление на операционния риск. Използваните методи и модели са сходни като при вероятността от неизпълнение, тъй като проблемът отново е от класификационен характер.

В последната част на главата се разглеждат ESG рисковете чрез моделиране на ESG рейтинги на компании от индекса S&P 500.

Представени са подходи за извличане на ESG информация, вкл. използването на текстови данни, статистически модели и ML техники за прогнозиране на рейтинги и оценка на дългосрочни рискове.

Значимостта на методите за машинно обучение се потвърждава чрез изведените резултати, които показват поле за приложимост. Валидираните модели в това изследване показват, че приложените алгоритми за машинно обучение в по-голямата си част превъзхождат по-малко сложните модели като логистичната регресия и GARCH. Подобриенето при някои алгоритми е значително, особено при проблемите, които са от тип класификационна задача.

Приложените NLP техники не само не доведоха до подобриение в резултатите, но и резултатът в по-лоши такива. Това не следва да се приема и тълкува като проблем на методите и технологиите, а по-скоро върху проблем, който изисква допълнително изследване – с по-голям обем от данни, по-голям брой наблюдения, алтернативни извадки от данни с по-хомогенен характер и други.

В процеса на разработка и последващият анализ на резултатите се потвърждават някои от недостатъците при алгоритмите на машинното обучение, които от ЕБО очертават:

- сложност на моделите, което води до предизвикателства при обяснението на резултатните стойности;
- липсата на проследимост и адекватно разбиране за целите на управленските функции;
- често наблюдение на т.нар. overfitting;
- трудно осигуряване на достатъчно квалифициран персонал.

Част от синтезираните предимства и недостатъци по-горе са срещани в публикации, семинари, обучения и регулаторни документи. Техният набор и магнитуд обаче често зависят от областта, в която се прилагат, и целите, които се поставят. С оглед на преобладаващо по-добрите резултати от количествения анализ и валидация, до голяма степен се потвърждават очакванията, с които са натоварени методите на машинно обучение. Тази допълнителна прецизност обаче е съпътствана със следните предизвикателства по време и след прилагането на ML:

- сложна архитектура на модела, която изисква оптимизация на множество хиперпараметри, вкл. тяхното влияние върху резултатите;
- трудно установяване на оптималния брой от итерации за търсене на най-подходящите хиперпараметри;
- несигурност около намерените оптимални параметри и дали текущо приложените не са в т.нар. локална точка на оптималност¹;
- по-бавно и трудно разработване на моделите спрямо класическите. Оптимизирането на параметрите при DeepAR например отне около 80 часа (включващи изчислителното време). При GARCH това време възлиза на 3 часа поради много по-малкото и прости параметри за оптимизация;
- оптимизирането на хиперпараметрите зависи изключително много от опита и познанията на прилагания алгоритмите за машинно обучение. Това означава, че намирането на абсолютната или глобалната точка на оптималност е трудна задача;

¹ Заб. Това е точка от пространството, в която е установена комбинация от параметри, които водят до по-добри стойности спрямо точките в непосредствена близост. Но в цялото пространство оптималната точка се намира на друго място.

- общото време за всички оценки през анализирания период при DeepAR отне средно 220 минути за всяка валутна двойка/инструмент, а GARCH изиска чувствително по-малко време (средно 0.5 минути)². Това прави възможно калкулиране на DeepAR базиран VaR в рамките на деня, но е доста по-бавен метод спрямо GARCH;
- сложност на моделите, което води до необходимост от значително количество обработки, анализи и познания, посредством които могат сравнително достоверно да бъдат обяснени резултатните стойности.

Важно е да се подчертае, че докладваните резултати се основават на конкретни извадки от наблюдения и ограничен набор от алгоритми. Използването на различна извадка или включването на допълнителни алгоритми може да доведе до различни резултати. Обичайно се очаква от методите на изкуствения интелект да са по-ефективни при работа с големи и неструктурирани набори от данни. Използването на различни данни и/или прилагането на различни методи за обработка може да доведе до различни резултати и изводи. Критичен фактор е т.нар. „feature engineering“, който играе съществена роля. Идентифицирането на взаимодействия и комбинации между отделни променливи, създаването на нови и други подобни техники могат да подобрят представянето на всички приложени алгоритми, включително да доведат до различни изводи от сравнителния анализ.

ЗАКЛЮЧЕНИЕ

² Заб. Резултатите зависят съществено от това, каква компютърна конфигурация е използвана, както и постигнатата архитектура при двата модела.

Заклучението представя в синтезиран аспект основните теоретични и емпирични резултати от проведеното дисертационно проучване. В него ясно и аргументирано са дефинирани изводите по отношение обекта на изследване. В съкратен и систематизиран вид са разгледани изпълнението на заложените цели и задачи на дисертацията.

В изпълнение на поставената цел на дисертационния труд бяха формулирани и проверени четири изследователски хипотези, които разглеждат значимостта, представянето, сравнителните предимства и предизвикателствата на алгоритмите на машинното обучение в контекста на финансовия риск мениджмънт. На база на това и проведеното изследване чрез настоящата дисертация бе достигнато до няколко извода.

Проведените теоретични и емпирични анализи потвърждават, че инструментите на машинното обучение заемат нарастващо място в социално-икономическите процеси и във финансовата сфера в частност. Изследването показва, че ефективността на машинното обучение следва да се оценява в контекста на приложението му и наличните ресурси. Класическите модели, макар и по-опростени, често предлагат по-бърза имплементация, лесна интерпретация и по-ниска изчислителна цена. А това невинаги е за сметка на представянето. Затова изборът между ML и традиционни подходи трябва да бъде информиран, контекстно зависим и базиран на емпирични показатели.

Сравнителният анализ между класическите методи (като логистична регресия и GARCH) и алгоритмите на машинното обучение (като XGBoost) разкри, че някои от по-сложните модели действително показват по-добро представяне, особено при задачи с класификационен характер. Високите стойности на дискриминационната способност (AUC, Somers' D) демонстрират превъзходството на някои от ML алгоритмите по отношение на точността на оценките.

Макар и да бяха установени случаи със значително подобрене в представянето, бяха идентифицирани и случаи с липса на такова или добавена стойност, която е сравнително ограничена. Особено се открие този аспект при прогнозирането на ESG рейтинг посредством анализ на текст от финансови новини посредством NLP техники. Макар и този извод да е по-скоро валиден за данните и предмета на моделиране, той е напълно валиден за практиката и пример за ситуация, в която интеграцията на сложни методи като NLP не би довела до добавена стойност, а напротив. Такъв е примерът и с VaR по отношение позиционния риск за акции – оценките на GARCH са достатъчно консервативни според приложените тестове, а DeepAR, макар и да реализира по-малко пробиви, е чувствително по-консервативен, което означава заделянето на повече капитал и ресурс, а понякога и пропускане на възможности.

Практическите резултати от сравнителния анализ потвърждават, че ML моделите могат да постигнат по-висока прецизност, но често за сметка на някои допълнителни усложнения и ограничения. Този аспект налага необходимост от внимателно претегляне между ползите и разходите при въвеждането на ML модели в реална практика. Машинното обучение не е временно технологично явление, а естествен етап в еволюцията на количествените методи. Много от използваните алгоритми имат исторически корени в класическата статистика и са се развили благодарение на нарастващите изчислителни възможности. Регулаторната рамка в Европа показва нарастващ интерес към прилагането на изкуствен интелект във финансовия сектор, но същевременно поставя изисквания за прозрачност, обяснимост и етичност.

IV. НАСОКИ ЗА БЪДЕЩИ ИЗСЛЕДВАНИЯ ПО ТЕМАТА НА ДИСЕРТАЦИОННИЯ ТРУД

С посочените основни изследователски насоки, влизащи в обхвата на дисертационния труд, проблематиката по въпроса за оценка на финансовия риск посредством машинно обучение не се изчерпва. Темата продължава да бъде актуална и може да се посочат следните насоки за бъдеща изследователска работа по въпроса:

1. Изследване на възможностите за оценка на риска в допълнителни аспекти от финансовия риск, основавайки се на максимално достоверни и актуални извадки от данни.
2. Разширяване на обхвата от изследвани алгоритми, методи и аспекти от представянето на моделите.
3. Макар и изследването да е направено с максимално реалистични и извлечени от практиката методи и данни, възможно е да се потърси потенциално партньорство с институции, които биха били склонни за подобен тип изследване в реална среда. Това би направило изводите и заключенията с още по-висока степен на валидност.

V. СПРАВКА ЗА НАУЧНИТЕ ПРИНОСИ В ДИСЕРТАЦИОННИЯ ТРУД

На база на постигнатите в дисертационния труд резултати могат да бъдат формулирани следните негови приносни моменти:

Първо. Извършен е системен анализ на концепцията за оценка на финансовия риск чрез инструментариума на машинното обучение. В резултат на това са идентифицирани ключовите категории, свързани с финансовия риск, тяхното място при изграждането на модели за финансова устойчивост и се разкрива, че машинното обучение е ключов катализатор на иновациите при изучаването на икономически и финансови процеси.

Второ. Чрез емпиричен анализ се разкрива, че в по-голямата част от случаите моделите за оценка на риска, базирани на машинно обучение, имат съществено по-добро представяне спрямо тези, базирани на традиционни методи. Това от своя страна оправдава очакванията, с които са натоварени инструментите, използващи машинно обучение.

Трето. Очертани са приложението, ресурсните ограничения и ситуациите, при които моделите за оценката на финансовия риск чрез машинно обучение не са достатъчно ефективни, включително на фона на класическите модели, което подчертава необходимостта от тяхната много прецизна контекстуална селекция и приложение.

Четвърто. Чрез широкоспектърен емпиричен анализ са идентифицирани ключови предизвикателства и ограничения при практическата реализация на модели за управление на финансовия риск, базирани на машинно обучение, като се формулира изводът, че този инструментариум не е временно технологично явление, а закономерен и на практика нов еволюционен етап в развитието на количествените методи във финансите.

VI. ПУБЛИКАЦИИ ПО ТЕМАТА НА ДИСЕРТАЦИОННИЯ ТРУД

Статии:

1. Dichev, A., Zarkova, S., & Angelov, P. (2025). Machine Learning as a Tool for Assessment and Management of Fraud Risk in Banking Transactions, *Journal of Risk and Financial Management*, 18(3), p. 130. <https://doi.org/10.3390/jrfm18030130>
2. Дичев, А. (2023). Дискриминационна способност при оценката за вероятност от неплатежоспособност посредством някои алгоритми за машинно самообучение, *Народностопански архив*, ISSN: 2367-9301, бр. 4, с. 17-30. <https://doi.org/10.58861/tae.ea-nsa.2023.4.02.en>
3. Дичев, А. (2023). Машинно самообучение при VaR като оценка за пазарния риск – предимства и недостатъци. *Годишен алманах "Научни изследвания на докторанти"*, ISSN: 1313-6542, бр. XVI (<https://www2.uni-svishtov.bg/almanahnid/title.asp?title=3048>)

Научни доклади:

1. Дичев, А. (2025). Етика в ерата на изкуствения интелект: „AI изпиране“ (AIW). Доклади от научна конференция „Знание, наука, иновации, технологии“ 2025, ISSN: 2815-3480, с. 446-456

VII. ДЕКЛАРАЦИЯ ЗА ОРИГИНАЛНОСТ

съгласно чл. 68 ал. 2 от Правилника за развитието на академичния състав в СА „Д. А. Ценов“

Долуподписаният Антонио Дичев с докторантски номер D010223294 декларирам, че:

Първо. Дисертационният труд на тема „*Оценка на финансовия риск посредством машинно обучение*“ е моя собствена, оригинална и автентична научна разработка, като в нея са изложени собствени идеи, анализи, текстове и коментари, базирани на достоверна информация, съответстваща на обективната истина.

Второ. При написването на дисертационния труд са спазени изискванията на Закона за развитието на академичния състав и Закона за авторското и сродните му права.

Трето. Научните резултати, които са получени, описани и/или публикувани от други автори, са цитирани в текста на дисертацията съгласно установените стандарти и са посочени надлежно в библиографията на дисертационната разработка.

Четвърто. Постигнатите в моя дисертационен труд резултати и неговите приноси не са заимствани от изследвания и публикации, в които нямам участие.

гр. Свищов
23.12.2025 г.

/докт. Антонио Дичев/