

МАШИННО САМООБУЧЕНИЕ ПРИ VAR КАТО ОЦЕНКА ЗА ПАЗАРНИЯ РИСК – ПРЕДИМСТВА И НЕДОСТАТЪЦИ

Антонио Валентинов Дичев

Стопанска академия „Димитър А. Ценов“ – Свищов

Катедра “Финанси и кредит

e-mail: antoniodichev@yahoo.com

Резюме: Изследването прави опит да изведе основните предимства и предизвикателства пред Deep Autoregressive (DeepAR) като един от модерните алгоритми за машинно самообучение (ML) както при неговото приложение за анализ на времеви редове, така и в частност за извеждане на оценка за стойност под риск Value at Risk (VaR). Анализът включва и оценка посредством Generalized Autoregressive Conditional Heteroscedasticity (GARCH) като един количествен метод, който е широко разпространен и прилаган от дълго време във финансовия сектор. Изведената оценка обхваща валутен риск (валутна позиция в JPY, USD и GBP) и позиционен риск за акции (дълга позиция в Apple и Microsoft Corporation). Съпоставката на резултатите от двата алгоритъма потвърждава количественото превъзходство на DeepAR, но се акцентира и върху някои практикоприложни предизвикателства. Това, от своя страна, прави използването на методите за ML подходящи за извеждането на VaR, но след анализ на предимствата и предизвикателствата.

Ключови думи: пазарен риск, VaR, машинно самообучение, риск оценка.

JEL: B23, C58, G32

VAR WITH MACHINE LEARNING AS MARKET RISK INDICATOR - ADVANTAGES AND DISADVANTAGES

Antonio Valentinov Dichev

Dimitar A. Tsenov Academy of Economics – Svishtov

Department of Finance and Credit

e-mail: antoniodichev@yahoo.com

Abstract: The research paper endeavors to elucidate the predominant benefits and hurdles associated with employing Deep Autoregressive (DeepAR), a cutting-edge machine learning (ML) algorithm, for time series analysis, particularly in the estimation of Value at Risk (VaR). The investigation further encompasses an evaluation using Generalized Autoregressive Conditional Heteroscedasticity (GARCH) models as a widely recognized and longstanding quantitative method prevalent within the financial domain. The derived valuation covers currency risk (with an open currency position in JPY, USD and GBP) and equity position risk (long position in Apple and Microsoft Corporation). The juxtaposition of outcomes derived from the two models substantiates the quantitative ascendancy of the machine learning methodology. Nonetheless, the study also underscores several pragmatic challenges. Consequently, the application of machine learning techniques is deemed appropriate for deriving VaR estimates, contingent upon a comprehensive evaluation of the incremental benefits vis-à-vis the concomitant challenges.

Key words: market risk, VaR, machine learning, risk assessment.

JEL: B23, C58, G32.

Въведение

Висока инфлация, ускорено повишаващи се лихвени нива и други пазарни фактори могат да влошат финансовите резултати, да редуцират преоценъчните резерви и дори да повлияят съществено на финансовата стабилност. През 2022 г. и 2023 г., заедно с повишаващите се лихви в Европа и САЩ, подобен тип проблеми са актуални и поставят редица въпроси за решаване от риск мениджмънта във финансовия свят. Откритите фактори и проблеми, в частност, се отнасят към пазарния риск като едно от ключовите направления на финансовия риск мениджмънт. Важността и актуалността на тези проблеми са допълнително подчертани от няколко случая на фалит и затруднения сред големи банки. Един от най-ярките примери за материализирани се пазарни рискове е фалитът на Silicon Valley Bank (SVB) през 2023 г.

Проблемите на една рамка за управление на риск могат да бъдат от разностранен характер. Един от ключовите аспекти, който често попада под фокуса на практиците, научните среди и регулаторните органи, е оценката на риска. Анализира се доколко е прецизна оценката на риска, дали отразява реалните нива на риск, нейното ниво на консерватизъм и други. От своя страна методите на “машинно самообучение“ (machine learning) са изключително актуални и често са посочвани като възможност за приложение в различни сфери, включително оценката на риска. Демонстрирани са и аспекти от публичните финанси, при които тези алгоритми имат добавена стойност, например в изследването на Zarkova, Kostov, Angelov, Pavlov, & Zahariev (Zarkova, Kostov, Angelov, Pavlov, & Zahariev, 2023).

Оценката за т.нар. ”стойност под риск“ (VaR) е един от ключовите измерители за пазарен риск. Показателят е много широко използван, особено в банковия сектор, където неговите стойности служат за множество от различни цели – риск оценка и мониторинг, дефиниране на риск апетит, определяне на необходим капитал и други. Един от добре известните и широко изследвани примери за събитие с подчертана важна роля на VaR като условие за вземане на решения в банковия сектор е т. нар. „London Whale“. Обстоятелствата и резултатите от това събитие са описани като “финансово бедствие” от Глобалната асоциация на специалистите по риск (GARP) и става част от учебниците с множество препоръки в различните аспекти от управлението на риска (GARP, 2020).

В контекста на изложеното **обект** на изследване в настоящата разработка е машинното самообучение. **Предмет** на изследването е извеждането на оценка за ”стойност под риск“ (VaR) чрез подходящи методи за машинно самообучение.

Изследователската хипотеза се определя, както следва: Чрез използването на подходящи методи за машинно самообучение се подобрява прецизността на VaR оценките, което обаче е съпътствано с допълнителни методически и изчислителни предизвикателства.

Целта на изследването е свързана с апробирането на подходящи алгоритми за машинно самообучение като инструмент за подобряване прецизността на оценката на пазарния риск. Основните **задачи** на разработката се свеждат до: 1) Обосновка на теоретична основа и преглед на научните изследвания по темата; 2) Апробиране на формулни траектории за VaR оценка чрез GARCH и чрез DeepAR; 3) Извеждане на основните положителни и отрицателни страни при прилагането на тези алгоритми за подобряване прецизността на VaR оценките.

1. Теоретични основи и преглед на научните изследвания по темата

В множеството достъпни ресурси често се използва следната дефиниция за машинно самообучение (ML):

„Една компютърна програма се учи от опит E по отношение на определен клас от задачи T и измерител за коректност P , ако при изпълнението на задачи T , оценено посредством P , се наблюдава подобрене при натрупването на исторически опит.“ (Mitchell, 1997, p. 2)

Лихвени нива, пазарни цени и др. се изменят постоянно, от което се повлияват цените на финансови инструменти и активи. Тези движения пораждаят вероятност (възможност) за реализиране на загуби и се наричат пазарен риск. Пазарният риск има множество разновидности в зависимост от вида на фактора, на чието влияние е изложена позицията. От позицията (гледна точка) на финансовите институции най-чести и ключови фактори на пазарния риск са: цени на акции, лихвени нива, валутни курсове, цени на стоки и други (GARP, 2020). Всяка отделна експозиция би могла да е изложена към един или повече пазарни фактори.

Много важно място и често срещан измерител за пазарен риск е стойността под риск (VaR). Показателят представлява количествена оценка за максимална потенциална загуба от конкретната стойност на инвестиция при зададен времеви хоризонт и ниво на доверителност в условията на нормален пазар (Astuti & Gunarsih, 2021). Концепцията е разработена през 90-те години на 20-и век и посредством нея се цели да се отговори на следния въпрос: Какво ниво на загуби би могла да донесе определена експозиция при зададена вероятност и за определен период от време? (J.P.Morgan, 1996) Повечето автори посочват значителния принос на финансовата институция J. P. Morgan за разработването и популяризирането на VaR като надеждни модели за оценка на риска.

1.1. Преглед на изследванията, апробиращи машинното самообучение при оценката за пазарен риск/VaR

Въз основа на прегледа на изследванията, апробиращи машинното самообучение, прави впечатление изследването на Fatouros & Makridis

(Fatouros, et al. 2023), които сравняват представянето на невронните мрежи при оценката за валутен риск (чрез VaR) спрямо някои традиционни алгоритми. Отчитат се предимства в прецизността на VaR посредством т.нар. DeepVaR модел. Авторският колектив очертава и някои важни насоки за бъдещи разработки и потенциал за развитие в посока: анализ на текст от новини, туйтове и други.

Сред най-актуалните научни изследвания по темата попада разработката на Arian, H., Moghimi, M., Tabatabaei, E., Zamani, S. (Arian, Moghimi, Tabatabaei, & Zamani, 2020). Те изразяват тезата, че световната икономика става все по-сложна, с което стандартните постановки и допускания за моделиране се променят, и изтъкват, че именно усъвършенстваните решения при изкуствен интелект могат да предоставят правилните инструменти за анализ на световния пазар. В тази връзка авторският колектив предоставя нов подход за измерване на пазарния риск, наречен "encoded VaR". Моделът е основан на невронна мрежа, наричана Variational Auto-encoders (VAEs). Encoded VaR е модел, който може да се използва за възпроизвеждане на пазарни сценарии от набор от данни за историческата възвръщаемост на акциите, като същевременно увеличава съотношението „сигнал:шум“, присъстващо във финансовите данни. Изтъква се и способността на модела да изучава структурата и зависимостта на пазара, без да прави никакви допускания за разпределението на възвръщаемостта. В това им изследване авторите сравняват Encoded VaR с единадесет други метода и доказват, че по отношение на представяне и прецизност моделът е конкурентен на голяма част от добре познатите алтернативи за оценка на VaR. Идентифицирани са конкретни области с възможност за допълнително проучване и изследване относно възможностите за калкулиране на VaR с т.нар. генеративни модели.

В същото време Dowling, M., Aziz, S. (Dowling & Aziz, 2019) изследват как решенията в областта на изкуствения интелект (AI) и машинното обучение (ML) трансформират управлението на риска. На първо място се предоставя нетехнически преглед на основните техники за изкуствен интелект и машинно обучение и как могат да са от полза за управлението на риска. След това се извършва приложен анализ, използвайки текущата практика и емпирични доказателства, за действителното прилагане на тези техники в областите на управлението на риска на кредитния риск, пазарния риск, операционния риск и съответствието („RegTech“). Авторите завършват своя труд с някои размисления относно настоящите ограничения и виждания за това, как областта би могла да се развие в краткосрочен и средносрочен план. В заключение се представя оптимистична картина за ролята на AI и ML в управлението на риска, но се отбелязват някои практически ограничения, особено подходящите политики за мениджмънт на данни, както и липсата на необходимия набор от определени умения в корпоративния свят. От своя страна Xiong, W. (Xiong, 2018) изследва една малко по-различна перспектива на ML и неговото значение за риск мениджмънта – валидирането на

VaR модели. За да се оцени доколко добре се представя един VaR модел, се извършва т.нар. валидационен анализ или бек тестове. На база броя ”пробиви” (загуби, надвишаващи стойността под риск) може да се определи доколко консервативни са оценките на модела за стойност под риск. Наличието на изключения обаче не означава непременно, че е налице проблем с модела. И именно тук е основният фокус на разработката. Авторът предлага количествен метод, базиран на ML, който класифицира тези ”изключения” в две групи: група на изключения поради ”пазарни движения” и такива поради проблем с модела. Макар и разработката да не се отнася до прякото използване на ML за оценка на риска, изследваният аспект е изключително важен за една рамка по управление на риска. Процесът по бек тестването на модели е неизменна част от управлението на риска, често извършвано от независима страна, която следва да потвърди или отхвърли адекватността на модела, вкл. да открие потенциални слабости или възможности за подобрене на анализирания модел. В изследването на Lokesh, S., Mitta, S., Sethia, S., Kalli, S., Sudhir, M. (Lokesh, Mitta, Sethia, Kalli, & Sudhir, 2018) обръщат внимание на изключително силното и бързо подобрене в технологиите, които на свой ред водят до по-високи възможности за обработка и съхранение на данни с по-добри алгоритми. Сред изтъкнатите области на Авторският колектив посочва разбиване на „табуто“, че фондовият пазар е предназначен само за хора, които са добре запознати с финансите. С оглед на това те разработват решение, което цели да информира заинтересования краен потребител за свързаните рискове и очакванията за увеличение или спад в стойността на инвестициите му. Разработката не се фокусира само върху финансовия риск, а цели предоставянето на цялостен продукт, в който рискът е един от аспектите, заедно с анализ на настроеността от социалните мрежи и прогнозиране на цената при съответния финансов инструмент.

Позовавайки се на най-актуалните научни достижения в областта, може да се изведе, че машинното самообучение би могло да се използва в управлението на пазарния риск, допринасяйки за допълнителна прецизност в количественото му измерване.

2. Описание на данните и използваната методология в изследването

Анализът по-долу извежда оценка за пазарен риск посредством едnodневен VaR при доверителен интервал от 99%. Изведената оценка за стойност под риск обхваща валутен риск (при открита валутна позиция в чуждестранна валута) и позиционен риск за акции (дълга позиция) без внедрени деривативни инструменти или опционалности. Изборът се спира на тези два типа пазарни риск фактори поради високото ниво на интерес у практики и научни среди. Конкретно подобрите инструменти за количествената част от изследването

са едни от най-търгуваните и ликвидни инструменти. Авторът прави това с пълното разбиране, че резултатите и изводите е възможно да не се потвърдят частично или напълно при инструменти с по-различни пазарни обеми и структура. Периодът и списъкът от капиталови ценни книжа и валутни двойки, които попадат в обхвата на изследването, са изведени в Таблица 1.

Таблица 1

Пазарни данни за инструменти предмет на оценка

| Инструмент / Валутна двойка | Период |
|-----------------------------|-------------------------|
| Apple | 01.01.2020 – 30.09.2023 |
| Microsoft Corporation | |
| EUR/USD | |
| EUR/JPY | |
| EUR/GBP | |

Източник: Yahoo! Finance

Данните, върху които са приложени моделите, са публично достъпни чрез платформата Yahoo! Finance¹.

2.1. Използвани алгоритми и методи за VaR оценка

Подбрани са по един представител на т.нар. традиционни (или класически) и ML методи за оценка. И двата метода са от авторегресионен тип. Предвид поставените цели и задачи на изследването в него няма да се извършва задълбочено описание и изследване на характеристиките на използваните алгоритми и модели.

Към традиционните алгоритми и модели, върху които акцентираме, попада GARCH (1,1), въведен от (Bollerslev, 1986) и е често използван инструмент във финансовата индустрия. Едно от най-популярните му приложения е свързано с моделиране динамиката на волатилността. Посредством разпределението на оценките за волатилност, от своя страна, се създава възможност за сравнително лесна и бърза калкулация на VaR (Value at Risk) при различни хоризонти и нива на доверителност. Друга характеристика на GARCH моделите е сравнително доброто им представяне при разпределение с т.нар. “дебели опашки”. Формулният апарат (Sun & Chen, 2012) за практическото му прилагане е, както следва:

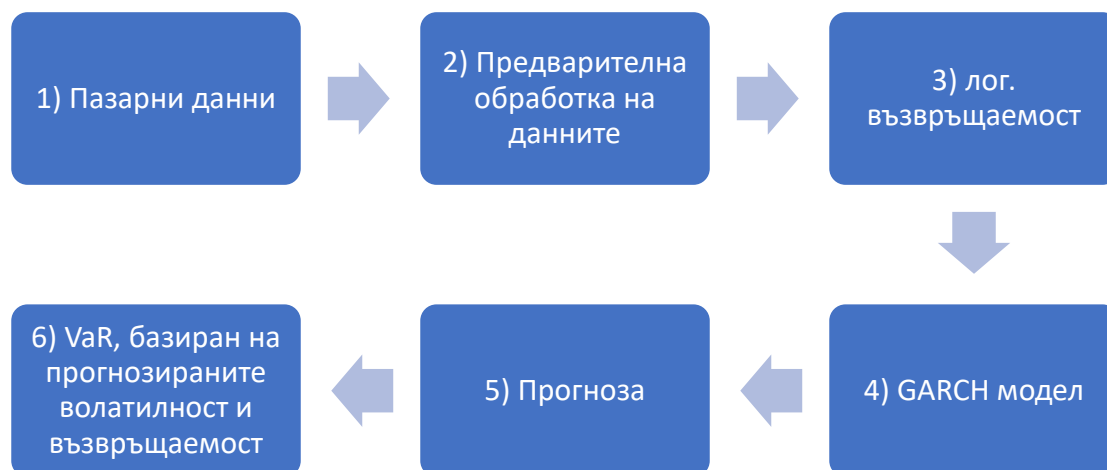
$$(1) X_t = \varepsilon_t \sigma_t$$

$$(2) \sigma_t^2 = \alpha_0 + \alpha_1 X_{t-1}^2 + \alpha_2 \sigma_{t-1}^2,$$

където $\{\varepsilon_t\}$ е с независимо и равномерно разпределение.

¹ Заб. Данните са извлечени на 05.10.2023 г.

Коефициентите α_0 , α_1 и α_2 приемат положителни стойности, а за да е изпълнено условието за стационарност, следва $\alpha_1 + \alpha_2 < 1$. Процесът по калкулация на VaR оценка посредством GARCH се представя чрез следната формална траектория на действие:



Източник: (Fatouros, et al., *DeepVaR: a framework for portfolio risk assessment leveraging probabilistic deep neural networks*, 2023)

Фигура 1. Процес по калкулация на VaR оценка посредством GARCH

На базата на апробирания модел се извеждат параметри на приложение на GARCH модела (вж. табл. 2). Приложеният machine learning алгоритъм е DeepAR² (Alexandrov, Benidis, & Bohlke-Schneider, 2020) и се прилага успешно в различни области и икономически сектори. Сред областите на приложение са безопасност на храните, прогнозиране на броя продажби по продукти, електропотреблението и други (Fatouros, et al., *DeepVaR: a framework for portfolio risk assessment leveraging probabilistic deep neural networks*, 2023).

Таблица 2

Параметри на приложения GARCH (p, q) модел

| Параметър | Стойност |
|---|----------|
| N (ист. набл. използвани за всяка отделна оценка) | 250 |
| p (Autoregressive Order) | 1 |
| q (Moving Average Order) | 1 |

Източник: Изчисления на автора

DeepAR е базиран на авторегресионна рекурентна изкуствена невронна мрежа (RNN). Основното, което различава RNN от другите големи групи невронни мрежи (напр. feed-forward NN, FNN), е, че информацията не се “движи само в една посока” – от входящ слой, през скрития слой (или

² Заб. DeepAR е част от групата на т.нар. Deep Learning алгоритми (клон на машинното самообучение).

т.нар. тегла) към изходящия. При RNN информацията може да премине през цикъл и процедурата за преминаване на информация от входящ слой към изходящ слой може да се повтори многократно, запомняйки информацията от предишните итерации. Концепцията за използване на памет при обучението на невронните мрежи е от съществено значение при алгоритмите.

За конкретната задача посредством алгоритъмът DeepAR се моделира условното разпределение $P(Z_{i,t_0:T} | Z_{i,1:t_0-1})$ на времевия ред Z_i за бъдещи времеви точки от t_0 до T , обуславяйки се на предходните стойности на Z_i от времева стъпка 1 до t_{0-1} .

Приложеният модел е с модифицирани (различни от заложените по подразбиране) хиперпараметри³, които са функция от тяхното оптимизиране и приемат следните стойности (вж. табл. 3):

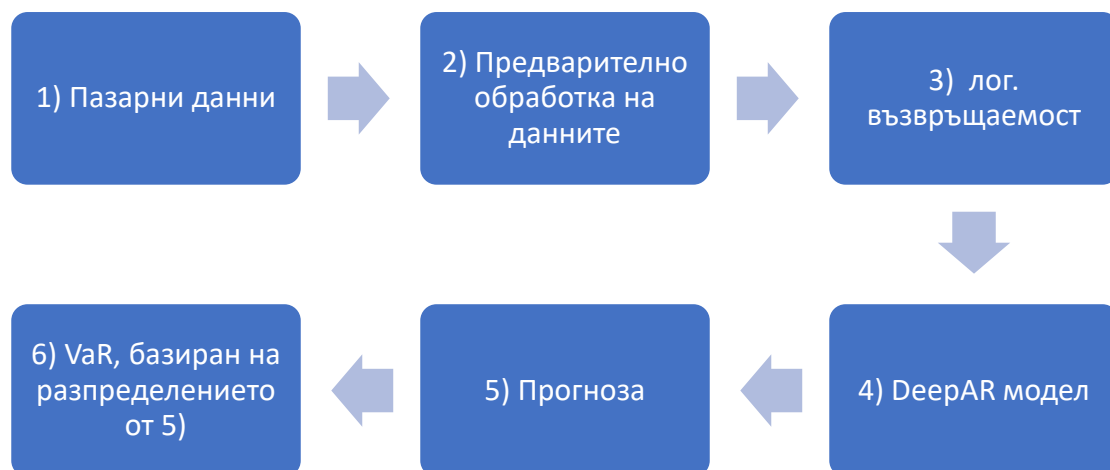
Таблица 3

Хиперпараметри на приложения DeepAR модел

| Параметър | MSFT, APPL | EUR/USD | EUR/JPY | EUR/GBP |
|----------------|------------|---------|---------|---------|
| dropout rate | 0.09 | 0.10 | 0.10 | 0.09 |
| hidden size | 55 | 50 | 55 | |
| max epochs | 5 | | | |
| context length | 15 | | | |
| num layers | 2 | | | |
| learning rate | 0.0001 | | | |
| num samples | 1 000 | | | |

Източник: Изчисления на автора

Процесът по извеждане на VaR оценка посредством DeepAR би могъл да се опише чрез Фигура 2.



Източник: (Fatouros, et al., DeepVaR: a framework for portfolio risk assessment leveraging probabilistic deep neural networks, 2023)

Фигура 2. Процес по калкулация на VaR оценка посредством DeepAR⁴

³ Заб. Настройки на конкретния алгоритъм, които не се “научават” от самите данни и които определят поведението на модела и колко сложна да бъде неговата архитектурата.

⁴ Заб. Изразеният по този начин процес предполага, че оптималните стойности на т.нар. хиперпараметри за алгоритъма са предварително установени.

Би могло да се твърди, че няма нещо необичайно в това оценките от конкретен модел да се различават спрямо наблюдаваните резултати по-късно. Възможно е това разминаване да е породено от случайни събития, да е в рамките на очакваното отклонение и да не означава непременно необходимост от редизайн и/или рекалибрация на конкретния модел. За да се оцени доколко разминаването е съществено и дали то е индикатор за проблем в модела за оценка на риск, се извършват т.нар. валидационни анализи. Посредством тях се идентифицират отклонения и същите биват детайлно анализирани. Част от най-често използваните статистически тестове за оценка степента на консервативност при VaR оценките е т.нар. биномен тест. Тестът е от групата на т.нар. непараметрични методи (Slaveva, 2021) и по конструкция се основава на допускане за независимост на събитията. Тестът се извършва, както следва:

H₀ (нулева хипотеза): Оценките на модела са достатъчно консервативни.

H₁ (алтернативна хипотеза): Оценките на модела подценяват нивото на риск.

При зададено ниво на доверителност q (напр. 95%) H_0 (нулева хипотеза) се отхвърля, ако броят на събитията е по-голям от критичната стойност c^* , дефинирана както следва (BCBS, Studies on the Validation of Internal Rating Systems, 2005):

$$(3) c^* = \min \left\{ c \mid \sum_{i=k}^n \binom{n}{k} ER^i (1 - ER)^{n-i} \leq 1 - q \right\},$$

където:

n е броят наблюдения (кредитополучатели при модели за кредитен риск, дни при едnodневни VaR модели и други);

ER – очакваният % събития (неплатежоспособност при модели за кредитен риск, отчетени загуби над определената стойност от VaR модела при пазарен риск и други);

$\binom{n}{k}$ – понякога срещано като “ n choose k ” (Guichard, 2016).

От Базелския комитет за банков надзор (BCBS) използват този статистически тест, за да дефинират три зони на отчетените резултати, наричайки това “подход на светофара” (BCBS, 1996). Посредством него се цели, в банковия сектор да бъде установено единно възприемане и тълкуване на индикаторите при VaR моделите за оценка на пазарния риск.

Акцентът при регулаторните и надзорни органи попада основно върху консервативността на оценките за риск и достатъчността на заделения капитал. Пред мениджмънта на банките и компаниите обаче стои още един проблем – оптимизацията и ефективността на наличните ресурси и капитала. С

оглед на това следва да се проследи дали оценката за риск не е твърде консервативна и не води до неефективно разпределяне на капитал. С други думи да се проследи дали оценките не са твърде консервативни и водещи до неефективност. При банковия сектор нивото на вътрешните политики и ресурси са от изключителна важност за финансовите резултати. Zahariev, A., Angelov, P., Zarkova, S. (Zahariev, Angelov, & Zarkova, 2022) изследват връзката между рентабилността на търговските банки в България и редица макроикономически фактори – БВП, безработица, инфлация и други. Изследването не потвърждава статистически значима връзка за изследвания период (2014–2020 г.), което фокусира вниманието още по-силно върху вътрешните политики и инструменти на Банките, като основен фактор за тяхната рентабилност.

3. Анализ на резултатите

Резултатите от биномния тест при 95% ниво на доверителност (гаранционна вероятност) показват, че при VaR (еднодневен, 99%) оценките посредством DeepAR имат по-малко пробиви при всеки един от анализирания инструмент и валутни двойки. Макар и с повече пробиви, оценките посредством GARCH също са с достатъчна консервативност и не се достига критичната стойност ($p\text{-value} > 0.05$) при нито един от изследваните инструменти и валутни двойки. С други думи, “подходът на светофара“ би оценил и двата модела като адекватни с достатъчно ниво на консерватизъм.

Таблица 4
Резултати от биномен тест

| Инструмент / валутна двойка | Пробиви | | P-value | |
|-----------------------------|---------|--------|---------|--------|
| | GARCH | DeepAR | GARCH | DeepAR |
| Apple | 4 | 2 | 0.92 | 0.99 |
| Microsoft Corporation | 7 | 4 | 0.54 | 0.90 |
| EUR/USD | 10 | 5 | 0.20 | 0.85 |
| EUR/JPY | 7 | 4 | 0.59 | 0.93 |
| EUR/GBP | 5 | 2 | 0.85 | 0.99 |

Източник: Изчисления на автора

За да придобием интуиция доколко оценките, базирани на невронната мрежа (DeepAR), не са твърде консервативни, са проследени средните стойности на VaR оценките при двата подхода (Таблица 5) за всеки един инструмент и валутни двойки. Впечатление прави, че при акциите и за една от валутните двойки (EUR/JPY) DeepAR би изискал от съответната институция да задели повече ресурс средно за анализирания период. При останалите две валутни двойки обаче освен по-добрите резултати при биномния тест наблюдаваме и по-ниски средни нива. Това потвърждава наблюденията и на (Fatouros, и др., 2023). С други думи освен спестяване на заделен ресурс и

капитал (за банки, прилагащи вътрешнорейтингов подход за пазарен риск) имаме и по-малко пробиви при тези две валутни двойки (Таблица 4).

Таблица 5
Средни стойности на VaR оценки

| инструмент / валутна двойка | GARCH | DeepAR |
|-----------------------------|-------|--------|
| Apple | 4.19% | 6.21% |
| Microsoft Corporation | 4.21% | 6.17% |
| EUR/USD | 2.48% | 1.77% |
| EUR/JPY | 1.77% | 1.90% |
| EUR/GBP | 2.64% | 1.49% |

Източник: Изчисления на автора

Следва да се отбележи, че при по-задълбочено оптимизиране хиперпараметрите на DeepAR би могло резултатите да се подобрят. Налични са възможности и за конструиране на допълнителни фактори, които би могло да се инкорпорират и при двата приложени метода. В изследването си Teller, Pigorsch, & Pigorsch (Teller, Pigorsch, & Pigorsch, 2022) разглеждат и синтезират набор от фактори, които могат да се конструират извън класическата форма и на двата алгоритъма. Тези допълнителни фактори биха могли да имат добавена стойност при моделиране на волатилността, а оттам и върху оценките за VaR. Важно е да се отбележи, че анализирането им ще допринесе за изясняването на начина и посоките на въздействие, но това може да е обект на бъдещо изследване.

С оглед на по-добрите резултати от биномния тест, вкл. по-ниски средни оценки за стойност под риск при две от валутните двойки, до голяма степен се потвърждават популярните и известни основни предимства от приложението на методи за машинно самообучение: по-висока прецизност на прогнозите и отчитане на по-сложни и нелинейни връзки. Тази допълнително 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 оптималност⁵;

⁵ 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.

- по-бавно и трудно разработване на моделите. Оптимизирането на параметрите при DeepAR отне на автора 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 DeepAR. Това означава, че намирането на абсолютната или глобалната точка на оптималност е много трудна задача;

- 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)⁶. Това прави възможно калкулиране на DeepAR, базиран VaR в рамките на деня, но е доста по-бавен метод спрямо GARCH;

- сложност на модела водеща да предизвикателства при обяснението на резултатните стойности⁷.

Част от синтезираните предимства и недостатъци по-горе са срещани в публикации, семинари, обучения и регулаторни документи (ЕВА, 2023). Техният набор и магнитуд обаче често зависи от областта, в която се прилагат, и целите, които се поставят.

Заклучение

Изведените количествени резултати от изследването, както и масовото разбиране за машинно самообучение, често поставят фокуса върху подобрата прецизност на оценките при използването на машинно самообучение във финансовата сфера. Евентуално полагане на последващи усилия и време, посветени в търсенето на оптимални хиперпараметри, могат да доведат до още по-добри количествени резултати при DeepAR. От своя страна изследването на допълнителни фактори, които да бъдат инкорпорирани и в двата приложени модела, може да доведе до промяна в резултатите и да направи изводите съвсем различни. Например би могло да се наблюдава свиване на разликата или точно обратното. Предвид това е важно да се отбележи, че полето за допълнителни количествени изследвания не се изчерпва с анализирания финансови инструменти, валутни двойки, период и количествени методи.

Заедно с вече идентифицираните предимства на ML е важно да се направи обобщение за изведените предизвикателства, които са основно в практикоприложен аспект. Някои от тях обаче биха могли да са сериозна пречка

⁶ Заб. Резултатите зависят съществено от това, каква компютърна конфигурация е използвана, както и постигнатата архитектура при двата модела.

⁷ Заб. Съществуват популярни методи за обяснение на връзките и интеракциите между отделните променливи в един модел. Например: SHapley Additive exPlanations (SHAP) и Local Interpretable Model-agnostic Explanations (LIME).

пред прилагането на тези методи. Това налага изключителното и задължителното търсене на баланс между ползите и недостатъците от това да се прилагат методи, които са по-сложни за имплементиране и разбиране. От това следва, че е много важно намирането на точката на баланс, която би могла да се намира на различно място в зависимост от конкретната задача и цел.

Използвани източници

- Alexandrov, A., Benidis, K., & Bohlke-Schneider, M. (2020). GluonTS: Probabilistic and Neural Time Series Modeling in Python. *Journal of Machine Learning Research*, 21(116), 1-6.
- Arian, H., Moghimi, M., Tabatabaei, E., & Zamani, S. (2020). *Encoded Value-at-Risk: A Predictive Machine for Financial Risk Management*.
- Astuti, P., & Gunarsih, T. (2021). Value-at-Risk Analysis in Risk Measurement and Formation of Optimal Portfolio in Banking Share. *JBTI : Jurnal Bisnis : Teori dan Implementasi terindex.*, 12(2).
doi:<https://doi.org/10.18196/jbti.v12i2.12263>
- BCBS. (1996). *Supervisory framework for the use of "backtesting" in conjunction with the internal models approach to market risk capital requirements*. Basel Supervision Committee on Banking.
- BCBS. (2005). *Studies on the Validation of Internal Rating Systems*.
- Bollerslev, T. (1986). *Generalized Autoregressive Conditional Heteroskedasticity* (Vol. 31). *Journal of Econometrics*. doi:10.1016/0304-4076(86)90063-1
- Dowling, M., & Aziz, S. (2019). AI and machine learning for risk management. *SSRN Electronic Journal*. Retrieved 09 25, 2023, from https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3201337
- EBA. (2023). *Follow-up report from the consultation on the discussion paper on machine learning for IRB models*.
- Fatouros, G., Makridis, G., Kotios, D., Soldatos, J., Filippakis, M., & D., K. (2023). DeepVaR: a framework for portfolio risk assessment leveraging probabilistic deep neural networks. *Digital Finance*, 5, 29-56.
doi:<https://doi.org/10.1007/s42521-022-00050-0>
- GARP. (2020). *Foundations of Risk Management*. Pearson.
- Guichard, D. (2016). *An Introduction to Combinatorics and Graph Theory*.
- J.P.Morgan, R. (1996). *RiskMetrics-Technical Document* (Fourth ed.).
- Lokesh, S., Mitta, S., Sethia, S., Kalli, S., & Sudhir, M. (2018). *Risk Analysis and Prediction of the Stock Market using Machine Learning and NLP*.
- Mitchell, T. (1997). *Machine Learning*. McGraw-Hill Science.
- Slaveva, K. (2021). *Методология и методика на емпиричните изследвания (Модул "Статистика")*.

- Sun, P., & Chen, Z. (2012). *How to apply GARCH model in risk management?* Barcelona: European Financial Management Association.
- Teller, A., Pigorsch, U., & Pigorsch, C. (2022). Short- to Long-Term Realized Volatility Forecasting using Extreme Gradient Boosting. *International Journal of Forecasting*.
- Xiong, W. (2018). *Machine Learning in Financial Market Risk: VaR Exception Classification Model*.
- Zahariev, A., Angelov, P., & Zarkova, S. (2022). Estimation of Bank Profitability Using Vector Error Correction Model and Support Vector Regression. *Economic Alternatives*(2), 157-170.
doi:10.37075/EA.2022.2.01
- Zarkova, S., Kostov, D., Angelov, P., Pavlov, T., & Zahariev, A. (2023). Machine Learning Algorithm for Mid-Term Projection of the EU Member States' Indebtedness. *Risks*, 11(4).
doi:<https://doi.org/10.3390/risks11040071>

СТОПАНСКА АКАДЕМИЯ „Д. А. ЦЕНОВ“ - СВИЩОВ


НАУЧНИ ИЗСЛЕДВАНИЯ
НА ДОКТОРАНТИ

ГОДИШЕН
АЛМАНАХ

ГОДИШЕН

АЛМАНАХ

НАУЧНИ ИЗСЛЕДВАНИЯ
НА ДОКТОРАНТИ



Том XVI, 2023

Книга 19

Том XVI, 2023 г.
Книга 19

Академично издателство
„ЦЕНОВ“ - Свищов

РЕДАКЦИОНЕН СЪВЕТ:

Доц. д-р Красимира Славева – главен редактор
Проф. д-р Марина Николова – зам. главен редактор
Доц. д-р Пепа Стойкова
Доц. д-р Ваня Григорова
Доц. д-р Христо Сирашки
Доц. д-р Петранка Мидова
Доц. д-р Николай Нинов
Доц. д-р Людмил Несторов

Екип за техническо обслужване:

Анка Танева – стилев редактор
Ст. преп. Иванка Борисова – превод и редакция
на английски език
Милена Александрова – технически секретар

Съдържание

Студии

| | |
|---|-----|
| Васил Пламенов Василев ТРАНСПОРТ И ИКОНОМИЧЕСКИ РАСТЕЖ: ФОРМИ НА ПРОЯВЛЕНИЕ И МЕХАНИЗМИ НА ВЪЗДЕЙСТВИЕ | 5 |
| Гергана Филипова Павлова СТАТИСТИЧЕСКИ АНАЛИЗ НА ДОХОДИТЕ НА ЗЕМЕДЕЛСКИТЕ СТОПАНСТВА ЗА ПЕРИОДА 2007 – 2022 ГОДИНА | 26 |
| Грета Иванова Иванова ПОДБОР НА СЛУЖИТЕЛИ В ДЪРЖАВНАТА АДМИНИСТРАЦИЯ В РЕПУБЛИКА БЪЛГАРИЯ – НОРМАТИВНА РЕГЛАМЕНТАЦИЯ И ПРАКТИЧЕСКО ПРИЛАГАНЕ | 49 |
| Йордан Чорбаджийски ОПТИМИЗИРАНЕ НА ЕКСПОРТА В СЕКТОР ВИНОПРОИЗВОДСТВО ПО ПРИМЕРА НА ВИНАРСКА ИЗБА „ЧЕРНОМОРСКО ЗЛАТО“ АД | 76 |
| Мария Анастасова Хаджихристева СТАТИСТИЧЕСКИ АНАЛИЗ НА ЗДРАВНОТО СЪСТОЯНИЕ НА НАСЕЛЕНИЕТО В БЪЛГАРИЯ | 95 |
| Момчил Мирославов Маринов РАЗВИТИЕ НА ЗАСТРАХОВАНЕТО „ЖИЛИЩА И ДОМАШНО ИМУЩЕСТВО“ В ЗАД „ОЗК ЗАСТРАХОВАНЕ“ АД | 117 |
| Ненко Василев Василев АКТУАЛНИ ПРЕДИЗВИКАТЕЛСТВА ПРЕД МАШИНОСТРОЕНЕТО В БЪЛГАРИЯ – СЕКТОРЕН АНАЛИЗ | 148 |
| Радка Иванова Василева КОЕФИЦИЕНТЪТ НА ВАРИАЦИЯ КАТО ВЪЗМОЖНОСТ ЗА АНАЛИЗ НА ПАЗАРА И УСТАНОВЯВАНЕ НА НЕОБХОДИМОСТТА ОТ ПРЕЗАСТРАХОВАТЕЛНА ЗАЩИТА ПРИ ИМУЩЕСТВЕНИТЕ ЗАСТРАХОВКИ В БЪЛГАРИЯ | 175 |
| Тоня Петрушева ФРАГМЕНТАРЕН АНАЛИЗ НА ДЕЙНОСТТА НА ТЪРГОВСКИТЕ ВЕРИГИ ЗА БЪРЗОБОРОТНИ ПОТРЕБИТЕЛСКИ СТОКИ В БЪЛГАРИЯ | 192 |
| Шенай Шемсиева Раимова ВЪЗДЕЙСТВИЕ НА ФИНАНСОВАТА ГРАМОТНОСТ ВЪРХУ ФИНАНСОВОТО БЛАГОСЪСТОЯНИЕ НА ИНДИВИДА | 219 |

Статии

| | |
|--|-----|
| Антонио Валентинов Дичев МАШИННО САМООБУЧЕНИЕ ПРИ VAR КАТО ОЦЕНКА ЗА ПАЗАРНИЯ РИСК – ПРЕДИМСТВА И НЕДОСТАТЪЦИ | 241 |
| Боряна Руменова Пейчева ФУНКЦИОНАЛНА РАМКА НА ДИГИТАЛИЗАЦИЯТА В МИТНИЧЕСКИЯ КОНТРОЛ | 255 |
| Виктор Димитров Маринов ВЪЗДЕЙСТВИЕ НА ОТВОРЕНИТЕ ИНОВАЦИИ ВЪРХУ ИКОНОМИЧЕСКОТО РАЗВИТИЕ – ВЪЗМОЖНОСТИ И ПРЕДИЗВИКАТЕЛСТВА | 271 |
| Галина Генева Илиева ИЗБОР НА ДОСТАВЧИК ОТ ФИРМАТА | 284 |
| Горян Благовестов Милев ДИНАМИКА НА ОТРАСЛОВАТА СТРУКТУРНА ТРАНСФОРМАЦИЯ В БЪЛГАРИЯ | 294 |
| Елка Узунова МЕТОДИКО-ОРГАНИЗАЦИОННИ АСПЕКТИ НА ИЗСЛЕДВАНЕ НА ДРЕБНОТО ПРЕДПРИЕМАЧЕСТВО В СФЕРАТА НА ТУРИЗМА | 305 |
| Йоана Иванова Първанова РЕГИОНАЛЕН ИКОНОМИЧЕСКИ РАСТЕЖ – СЪЩНОСТ, ЗНАЧЕНИЕ И ДИНАМИКА ПРИ ПРОВЕЖДАНЕ НА ДЪРЖАВНИТЕ ПОЛИТИКИ | 317 |
| Йордан Стефанов Генов КОМУНИКАЦИЯТА КАТО ЧАСТ ОТ ПРЕНОСИМИТЕ КОМПЕТЕНЦИИ | 336 |
| Любомир Василев Георгиев РОЛЯТА НА УПРАВЛЕНСКОТО РЕШЕНИЕ В СЪВРЕМЕННАТА ОРГАНИЗАЦИЯ | 358 |
| Мария Петрова Дачева КРИЗИСЕН МЕНИДЖМЪНТ ПРЕЗ COVID-19 И ЕФЕКТА МУ ВЪРХУ ПРОФЕСИОНАЛНОТО УПРАВЛЕНИЕ НА ОФИС СГРАДИ | 368 |
| Миглена Трифонова Маринова УСТОЙЧИВОТО СЧЕТОВОДСТВО В МИННОДОБИВНИТЕ ПРЕДПРИЯТИЯ – ИНТЕГРАЦИЯ В СТРАТЕГИЧЕСКИЯ ПОДХОД | 378 |

| | |
|---|-----|
| Николай Василев Тодоров КРЪГОВИ ИКОНОМИЧЕСКИ СПОСОБИ В МЕТОДОЛОГИЯТА ЗА ОПРЕДЕЛЯНЕ НА ТАКСА БИТОВИ ОТПАДЪЦИ | 392 |
| Онник Таракчиян АНАЛИЗЪТ В УПРАВЛЕНИЕТО НА ФАРМАЦЕВТИЧНИЯ СЕКТОР: ТЕОРЕТИКО – ПРИЛОЖНИ АСПЕКТИ | 405 |
| Петър Ангелов Чернаев ДИГИТАЛНА ТРАНСФОРМАЦИЯ НА ЖИВОТНОВЪДНИЯ БИЗНЕС: ПРЕДИЗВИКАТЕЛСТВА И ВЪЗМОЖНОСТИ | 415 |
| Пламен Станчев Илиев ЦЕНОВА ДИНАМИКА НА ЖИЛИЩНИЯ ПАЗАР В БЪЛГАРИЯ | 428 |
| Пламена Йорданова Колева НОРМАТИВНО РЕГЛАМЕНТИРАНЕ НА СТАТИСТИКАТА НА ТУРИЗМА | 445 |
| Ралица Сирашка НЕОБХОДИМОСТ ОТ ЕКОЛОГОСЪОБРАЗНИ ПРЕДПРИЕМАЧЕСКИ УМЕНИЯ В СЪВРЕМЕННИЯ АГРОБИЗНЕС | 464 |
| Росен Здравков Тумбев ПОЛОЖИТЕЛНАТА НАГЛАСА КЪМ ЗДРАВЕ НА РАБОТНОТО МЯСТО – СЪЩЕСТВЕН КОМПОНЕНТ ЗА ОРГАНИЗАЦИОННО ЗДРАВЕ | 480 |
| Стелиян Богданов Стефанов ИЗСЛЕДВАНЕ НА НЕРАВЕНСТВОТО ПРИ РАЗПРЕДЕЛЕНИЕ НА ДОХОДИТЕ В БЪЛГАРИЯ И ЕС | 491 |
| Тодор Георгиев Гогов ЗНАЧЕНИЕ НА ВЪТРЕШНИЯ ОДИТ В БОРБАТА С ИЗМАМИТЕ В ОРГАНИЗАЦИИТЕ | 504 |
| Цветомира Георгиева Велева ПРЕДИЗВИКАТЕЛСТВА ПРЕД ОМНИКАНАЛНОТО БАНКИРАНЕ | 522 |

ГОДИШЕН
АЛМАНАХ
НАУЧНИ ИЗСЛЕДВАНИЯ НА ДОКТОРАНТИ
Студии и статии
Том XVI – 2023, книга 19

Даден за печат на 10.11.2024 г., излязъл от печат 15.11.2024 г.
Поръчка № 18907; формат 16/70/100; тираж 50

ISSN 1313-6542

Издателство и печат: Академично издателство „Ценов“
Свищов, ул. „Цанко Церковски“ 11А