



Стопански факултет

Михаил Веселинов Янчев

Автореферат

На дисертационен труд на тема:

Моделиране на икономическата несигурност: Методи, оценка и приложения на вероятностните прогнози

За придобиване на научна степен „доктор“ в
направление 3.8 Икономика

Научен ръководител: **доц. д.ик.н. Антон Герунов**

София

2023

Съдържание

Въведение	2
I. Преглед на дисертацията	3
Актуалност и значимост на изследването.....	3
Обект и предмет на изследването.....	4
Цели и задачи на изследването	4
Хипотези.....	5
Обхват на проучването	6
Методология на изследването	6
Източници на данни.....	7
Стойност и оригиналност на изследването.....	7
Ограничения на изследването	8
Възможности за бъдещи изследвания	9
II. Структура на дисертацията	10
III. Основни резултати от дисертацията	13
Глава 1: Икономическо прогнозиране и несигурност	13
Несигурност - дефиниция и класификация за целите на икономическото прогнозиране.....	13
Икономическо прогнозиране и развитие на прогнозирането на плътността	21
Глава 2: Вероятностно прогнозиране с помощта на изкуствени невронни мрежи	27
Глава 3: Приложения на дълбоката квантилна вероятностна регресия.....	40
Прогнозиране в реално време на рецесията свързана с пандемията през 2020 г. в малки отворени икономики	40
Вероятностно прогнозиране на цените на природния газ на Газовия Хъб Балкан използвайки дълбоко самообучение	48
Разширени приложения: Измерване на алеаторната и епистемичната несигурност при прогнозиране на потребителската инфлация в България	55
IV. Научни и приложни приноси	64
V. Съответни публикации	65
VI. Заключение	65

Въведение

Несигурността е основна характеристика на бъдещето и настоящето. Вземането на оптимални решения, свързани с бъдещи събития, изисква, от една страна, дефиниране на възможните изходи от тези събития, а от друга - опит за категоризиране и измерване на несигурността, която ги съпътства. Това важи за вземането на решения както на ниво индивид, така и на ниво организация. Много икономически и бизнес решения изискват както прогнозиране на бъдещи събития, така и измерване на свързаната с тях несигурност. Според изтъкнатия икономист и мислител Франк Х. Найт (1921 г.) понятието „риск“ обхваща несигурността, която може да бъде измерена, и за да се разделят двете понятия напълно, несигурността трябва да се отнася само до неизмеримото. Това определение доминира в икономическото мислене през последния век и е от съществено значение за развитието на областта на управлението на риска. Икономисти, статистици и инженери са разглеждали и размишлявали върху понятието за несигурност и начините за нейното измерване и в резултат на това са разработени различни категоризации и дихотомии.

Един малко по-различен социологически възглед за несигурността е представен от Улрих Бек (1992 г.), който твърди, че модерността е довела до нови нива на сложност в глобалните социално-икономически системи, което от своя страна е създавало нови рискови фактори като финансови кризи, рецесии и климатични промени, които се съчетават с природните рискове, с които човешките общества са се сблъскали в миналото. В този смисъл икономическата несигурност се поражда от поведението на индустриите и правителствата и взаимодействието между тях. Определящи фактори за това са фискалната и паричната политика, търговските и инвестиционните потоци, както и международното и националното политическо развитие. На макроикономическо равнище рисковете често са свързани с икономически шокове и натрупване на дисбаланси. На ниво предприятие макроикономическите рискове са актуални, но могат да се идентифицират и рискове, свързани с развитието на конкретен пазар или верига на доставки, или на самата организация.

Все повече изследвания се фокусират върху измерването и моделирането на рисковете на ниво предприятие и на ниво икономика. Концепцията за „стойност под риск“, която произхожда от областта на управлението на финансовия риск (Markowitz, 1959), отскоро е приложена в други области като макроикономиката, което доведе до аналитичен подход, наречен „растеж под риск“, който се използва от институции като МВФ в задачата за мониторинг на глобалния риск (Prasad et al., 2019). По подобен начин настоящата дисертация има за цел да дефинира рамка и подход, които позволяват както прогнозирането на бъдещи събития, така и измерването на несигурността около прогнозите за икономически показатели от всякакъв вид, независимо дали са на микроикономическо или макроикономическо равнище. Тази рамка би била особено полезна, когато вземащият решение или

прогнозиращият е изправен пред реализацията на събитие с ниска вероятност или неочакван шок. Успоредно с това изследването черпи вдъхновение от бързо развиващата се област на машинното самообучение и дълбокото самообучение, за да предложи нов подход към вероятностното прогнозиране.

Изследването се основава на емпирични резултати в областта на икономиката. Заключениета на изследването имат важно значение за вземането на икономически решения в условията на несигурност както на ниво предприятие, така и на национално ниво. Нещо повече, резултатът от изследването е рамка, която може да бъде приложена в широк кръг от области като макроикономика, енергетиката, финансите и други.

I. Преглед на дисертацията

Вероятностното прогнозиране има ясни предимства в сравнение с по-често използваното точково прогнозиране, което е все още преобладаващо в икономиката. В контекста на редки събития като пандемията от коронавирус или руската инвазия в Украйна и произтичащата от тях изключителна икономическа нестабилност, вероятностното прогнозиране става незаменимо. Основната цел на настоящата дисертация е да се определят най-съвременните методи за вероятностното прогнозиране в областите на икономиката, статистиката и машинното самообучение и да се предложат нови подобрения, които могат да имат практическа полза за целите на икономическо прогнозиране. За постигането на тази цел е извършено мултидисциплинарно изследване и е предложен нов подход към вероятностното прогнозиране, който е приложен към няколко проблема, представляващи интерес сред икономистите.

Актуалност и значимост на изследването

От началото на 21-ви век се случиха две големи глобални събития, които поставиха пред голямо предизвикателство както прогнозиците, така и лицата, вземащи решения. Първото е световната финансова криза от 2007-2009 г. и последвалата я дълбока рецесия, чиито мащабни последици засегнаха много икономики по света. Макар че кризата беше реализация на риск с ниска вероятност (вж. Makridakis et al. 2009; Chen 2019), в ретроспекция стана ясно, че тя е причинена от натрупване на системен риск, който се оказа видим във финансовите данни (Altunbas et al., 2017).

Второто събитие е пандемията от коронавирус през 2020 г., която принуди много правителства по света да въведат политики на локдаун, което на практика доведе до рязка икономическа рецесия в целия свят. Макар че подобно на световната финансова криза пандемията също беше реализация на събитие с ниска вероятност (Антипова, 2021 г.), тя беше напълно неочакван шок, който трудно може да се счита за предвидим. Въпреки това въздействието ѝ върху икономиката можеше да бъде количествено определено в краткосрочен план, както показват резултатите от настоящото изследване, което е важен урок за бъдещето.

По време на писането на този текст в Украйна се води война. Освен хуманитарната криза и екзистенциалните последици от този военен конфликт, има и сериозни икономически последици като заплахата за глобалното предлагане на храни и безпрецедентната енергийна криза, която се разгърна през 2022 г. Подобно на другите два примера, несигурността, която подобни събития внасят, се отразява на нациите, предприятията и отделните хора и на тяхната способност да вземат информирани решения. Ето защо е наложително да можем да прогнозираме и измерваме несигурността в условията на такива слабо вероятни събития и неочаквани сътресения, за да вземаме оптимални решения по отношение на бъдещите реализации.

Целта на настоящото изследване е да се формулира рамка, която може да се използва от вземащите решения както в държавните, така и в частните организации, когато това е свързано с прогнозиране на важни икономически показатели. Освен това проучването има за цел да наложи използването на вероятностни прогнози като основен подход в ситуации, характеризиращи се с повишена степен на риск и несигурност.

Обект и предмет на изследването

Обект на изследване е икономическата несигурност. Тя включва измерими степени на несигурност, които се отнасят до икономическите условия в определен регион или в световен мащаб, измерени чрез различни икономически показатели.

Обект на изследването е прогнозирането на икономическата несигурност. Освен това фокусът на изследването е разработването на нова архитектура на невронна мрежа за вероятно прогнозиране, която се основава на концепцията за квантилна регресия и използването на изкуствени невронни мрежи.

Цели и задачи на изследването

Целта на дисертационния труд е да се разработи обща архитектура на невронна мрежа за моделиране и прогнозиране на икономически рискове и да се установи вероятно прогнозиране като необходимо в ситуации, характеризиращи се с редки събития и екстремни шокове, като икономически кризи и природни бедствия. За да се постигне целта на изследването, са дефинирани следните изследователски задачи:

1. Извършване на задълбочен преглед на литературата по темите за несигурността в икономиката и машинното самообучение, икономическото прогнозиране, и вероятностното прогнозиране в статистиката и дълбокото самообучение.
2. Разработване на архитектура за невронна мрежа за икономическо моделиране и прогнозиране, която може да позволи количествено

определяне на несигурността и да се използва в различни икономически контексти и за прогнозиране на времеви редове като цяло.

3. Оценка на предложената архитектура за дълбоко обучение и нейната относителна полезност в сравнение с установени еталони в рамките на различни приложения.
4. Прилагане на предложената архитектура за невронна мрежа за целите на прогнозиране на свързаната с пандемията рецесия в четири малки отворени икономики
5. Прилагане на предложената архитектура за невронна мрежа за целите на прогнозирането на цените на природния газ в Европа след руската инвазия в Украйна
6. Прилагане на предложената архитектура за невронна мрежа за целите на конструирането на ветрилообразни графики за инфлацията в България

Така описаните задачи водят до постигането на целта на дисертацията и показват как получената рамка може да бъде приложена в реални случаи.

Хипотези

Основната изследователска хипотеза е, че може да се формулира обща архитектура за моделиране и прогнозиране на икономическата несигурност, която би превъзхождала набор от референтни модели, особено в ситуации, свързани с редки събития и неочаквани шокове. Работните хипотези са следните:

1. Предложената рамка за вероятностна регресия, базирана на дълбоки квантили, може да постигне по-добри резултати от различни статистически показатели и показатели за машинно самообучение в редица задачи като прогнозиране на рецесии, свързани с пандемии, прогнозиране на цените на природния газ на Газовия Хъб Балкан и прогнозиране на инфлацията в България.
2. Общото семейство разпределения, като например семейството на разпределенията на Хиперболичен синус – Хиперболичен аркуссинус, е подходящо за моделиране на различни икономически показатели, като БВП, инфлация и цени на природния газ, а получените в резултат на това прогнозни разпределения имат по-добра точност.
3. Методите, заимствани от областите на машинното самообучение и дълбокото самообучение, като например използването на повече от една целева функция, оценката на няколко квантили едновременно и допълването на традиционните целеви функции с подобрения, които се отнасят до проблема с пресичането на квантили, могат да доведат до подобрения в полезността на прогнозите в сравнение с установени подходи за прогнозиране.
4. Данните за БВП, показателите за икономическите нагласи и финансовите показатели, свързани с общите индекси на фондовите пазари и доходността

на облигациите, обхващащи световната финансова криза и последвалата я рецесия, могат да бъдат полезни при прогнозиране на свързаните с пандемията рецесии.

Всички работни хипотези се проверяват емпирично. Хипотези 1 и 2 изискват анализ на различни наблюдавани разпределения, които представляват интерес, и оценка на техните моменти. Хипотеза 2 допълнително изисква използването на теста на Колмогоров-Смирнов за оценка на съвместимостта на предложеното семейство от разпределения на Хиперболичен синус – Хиперболичен аркуссинус с наблюдаваните разпределения на изследваните икономически показатели. При проверката на хипотези 3 и 4 се използват техники за оценка на точността и сравнение между конкурентни подходи.

Обхват на проучването

Изследването е насочено към моделирането и прогнозирането на икономически рискове и особено в ситуации, свързани с редки събития и неочаквани сътресения, като световната финансова криза от 2007-2009 г. и пандемията от коронавирус през 2020 г. В методологично отношение проучването разчита в голяма степен на утвърдени процедури в областта на икономическото прогнозиране, както и се позовава на утвърдени и нови подходи от областта на машинното самообучение и дълбокото самообучение.

Що се отнася до времевия обхват на емпиричния анализ, проучването обхваща приблизително периода след 2000 г. до настоящия момент на написване на дисертацията. В географски план изследването разглежда както глобални, така и регионални събития и въздействия. В конкретния случай на прогнозиране на рецесията, свързана с пандемията, географският обхват включва България, Литва, Естония и Румъния. Казусът за прогнозиране на цените на природния газ е съсредоточен върху България и нейните взаимовръзки с европейския пазар на природен газ. В последния казус, посветен на прогнозирането на инфлацията, географският обхват е стеснен само до България.

Методология на изследването

Проучването се основава на научния метод, като се прилагат внимателно наблюдение и събиране на данни, обективизъм и строг скептицизъм, формулиране на хипотези чрез индукция, проверка на изводите, основани на формулираната хипотеза, чрез тестове, основани на измервания, и повтарящо се уточняване или отхвърляне на първоначалните хипотези въз основа на резултатите и заключенията. За целите на прегледа на съответната литература са използвани методите на анализ и синтез, както и на индукция и дедукция. От друга страна, интердисциплинарният подход дава възможност за разбиране и оценка на заключения и резултати от различни научни области като икономика, иконометрия, статистика, управление на риска и машинно самообучение.

Анализът на конкретни процедури за моделиране и прогнозиране на данни изисква методи от областите на статистиката, иконометрията и машинното самообучение. За целите на вероятностното прогнозиране са разгледани и използвани няколко класа процедури - от напълно параметрични методи като авторегресионни модели на условна хетероскедастичност, през напълно непараметрични модели като ядрени оценки на плътността (kernel density methods) до хибридни полупараметрични процедури. Формулират се статистически хипотези и се извършват формални тестове, когато е необходимо, за да се подкрепи дадено заключение или да се обоснове изборът на изследователя. Извършват се съответните техники за оценка и се изчисляват съответните показатели, за да се оцени ефективността на конкурентните процедури. Тези количествени методи дават възможност за проверка на работните хипотези и за постигане на целите на дисертацията.

Източници на данни

Тъй като основните изследователски хипотези в тази дисертация се потвърждават емпирично, данните са основна предпоставка в това изследване. По-голямата част от емпиричния анализ е извършен върху данни от първични източници на данни, които са посочени в текста, където е уместно. Тъй като тези доставчици на първични данни имат строги методологии при събирането и разпространението на данни (например Евростат, МВФ, НСИ), качеството на данните се счита за оптимално и не е извършвано допълнително подобряване на качеството им. Някои от използваните данни идват от цитирани източници, което също е ясно посочено.

Всички изчисления, свързани с анализа на дисертацията, са направени с помощта на езика за програмиране Python 3.x и R 4.x. За всички реализации на изкуствени невронни мрежи е използвана рамката с отворен код TensorFlow (Abadi et al., 2016), първоначално разработена от Google. За повечето изчисления, свързани с резултатите в дисертациите, се използва нормален компютърен хардуер. В редки случаи на използване, като оптимизиране на хиперпараметри на изкуствени невронни мрежи, е използвана по-специализирана конфигурация, използваща GPU хардуер.

Стойност и оригиналност на изследването

Изброените приноси на дисертацията имат потенциала да увеличат познанието в областите на икономиката и машинното самообучение и съответно подобластите на икономическо прогнозиране и дълбоко самообучение.

На първо място, обсъждането на несигурността, нейната дефиниция и класификация са полезни за изясняване на термина и концепцията в контекста на икономическото прогнозиране. Това води до общо разбиране, намалява семантичната двусмисленост и дава възможност за ясно разграничение, което е от

съществено значение за количественото определяне на несигурността. Тъй като едно изследване, фокусирано върху икономическото вероятностно прогнозиране, може да пострада от гледна точка на двусмисленост и липса на точност, ако терминът "несигурност" се използва като саморазбиращ се, е ценно да се концепцията да се дефинира точно.

Предложеният модел наречен дълбока квантилна вероятностна регресия (deep quantile-based probabilistic regression или на кратко DQPR) може да бъде полезен при редица задачи за прогнозиране в икономиката - както макроикономически, така и микроикономически. Тъй като прогнозирането е важно за вземането на решения на всяко ниво на агрегиране, а количественото оценка на несигурността има доказана информационна стойност, този подход е ценен инструмент в подобни задачи. Тъй като алеаторната и епистемичната несигурност могат да се оценят поотделно, може да се съсредоточим само върху мярката за несигурност, която ни интересува. Освен това DQPR може да се използва в области извън икономиката, където прогнозирането на времеви редове и количественото определяне на несигурността биха били от съществено значение, тъй като подходът е универсален по отношение на прилагането му.

Приложенията на DQPR са нови както по отношение на обхвата, така и на темата. Темите за икономическата рецесия, свързана с пандемията, и нестабилността на пазарите на природен газ в Европа се отнасят до съвсем скорошни събития, които могат да имат последици за десетилетия напред. Демонстрирането на това как да се извършва прогнозиране в периоди, характеризиращи се с повишена несигурност, би било от полза за подобни научни изследвания в бъдеще.

Ограничения на изследването

Проучването има своите ограничения, които трябва да бъдат взети предвид и обсъдени. Вероятностното прогнозиране на времеви редове е много широка област на изследване в множество дисциплини като икономика, иконометрия, статистика, инженерни науки и машинно самообучение, и това са само някои от тях. Поради това настоящото изследване не претендира за абсолютна изчерпателност на всички методи и подходи към вероятностното прогнозиране, а вместо това се фокусира върху тези, които се считат за най-влиятелни и практични. Нещо повече, подтеми като изкуствени невронни мрежи или дълбоко самообучение, бейсови методи и бейсови невронни мрежи сами по себе си са доста обширни и е трудно да се твърди, че са изчерпани в дисертацията. Въпреки това, от всички разгледани теми беше поставена целта да се представят най-важните и влиятелни, най-широко използваните, най-утвърдените или, от друга страна, най-обещаващите нови методи в посочените по-горе дисциплини.

По отношение на предложения нов модел за дълбока квантилна вероятностна регресия, е важно да се спомене, че въпреки че са разгледани значителен брой различни архитектури както чрез ръчни, така и чрез автоматични итерации, не

може да се твърди, че търсенето е изчерпателно. Освен това е важно да се вземе предвид, че за всяка конкретна задача оптималната архитектура може да бъде съвсем различна и следователно тази архитектурна оптимизация е много специфична за конкретната задача. От друга страна, не е извършен задълбочен анализ на асимптотичните свойства на този подход, за да се проверят напълно неговите преимущества и недостатъци. Също така не е извършено задълбочено кръстосано сравнение на база на различните приложения и по-голям брой методи, тъй като това беше сметнато за маловажно в сравнение с прилагането на подхода към разглежданите прогностични задачи.

И накрая, по отношение на приложенията на предложения подход за вероятностно прогнозиране, следва да се спомене, че фокусът е върху икономиката на България и подобни страни от Източна Европа. Поради това подходът не е тестван в контекста на държави, които разполагат с по-богат набор от данни, като САЩ, Обединеното кралство или други държави от ЕС като Германия или Франция. Това беше мотивирано главно от натрупания опит и познание свързани с българската икономика, но и от общата липса на подобни изследвания в областта, които да се фокусират върху България или Източна Европа.

Възможности за бъдещи изследвания

Обсъдените ограничения на проучването откриват и възможности за бъдещи изследвания. На първо място, научни области извън традиционно свързаните с икономиката могат да бъдат проучени за напредък и възгледи по темата за вероятностното прогнозиране на времеви редове. Такива области, по-малко свързани с икономиката, в които са направени важни и интересни заключения и постижения, свързани с вероятностното прогнозиране, са метеорологията, неврологията и медицината. От друга страна, поради бързото натрупване на идеи и публикации в области като изкуствените невронни мрежи и дълбокото самообучение, е целесъобразно редовно да се преглежда най-новата литература в търсене на по-нови архитектури, алгоритми за оптимизация, техники за количествено определяне на несигурността или бейсови методи.

По отношение на предложената DPQR архитектура би било целесъобразно да се направят допълнителни изследвания на нейните асимптотични свойства. Освен това би било интересно да се тества в по-широк спектър от задачи - дори и такива, които са извън обхвата на икономиката. Например би било интересно да се приложи към задачи за прогнозиране на положителни данни за брой, където би било подходящо разпределението на Пуасон. По подобен начин ефективността му би могла да се сравни с по-голям набор от подобни вероятностни алгоритми. Пречката там би била, че повечето чисто вероятностни методи все още не са толкова достъпни и лесни за използване, колкото традиционните методи за точково прогнозиране.

В заключение, би било интересно да се възпроизведат резултатите от проучванията на свързаните с пандемията рецесии и цената на природния газ по време на войната в Украйна за по-широк географски обхват. По отношение на първата тема за рецесиите, свързани с пандемията, би било интересно да се приложи предложеният модел DQPR към съвкупните времеви редове на ЕС, данни за отделните членове на ЕС или данни за САЩ, за да се сравнят резултатите му с други методи в съществуващите изследвания. За последната тема за прогнозиране на цените на природния газ би било интересно подходът да се приложи към данни от други световни газови хъбове в САЩ и Азия. Такива сравнителни проучвания могат да разкрият плюсовете и минусите на подхода в различни контексти и да допринесат за по-нататъшното му развитие.

II. Структура на дисертацията

Дисертационният труд се състои от три глави, увод, заключение, литература и две приложения. Главите следват логично поставените преди това цели и задачи на изследването.

Съдържание

Въведение	5
Актуалност и значимост на изследването	6
Обект и предмет на изследването.....	7
Цели и задачи на изследването	7
Хипотези	7
Обхват на проучването.....	8
Методология на изследването.....	9
Източници на данни.....	9
Структура на дисертацията.....	10
Глава 1: Икономическо прогнозиране и несигурност	11
1.1 Несигурност - дефиниция и класификация за целите на икономическото прогнозиране	11
1.1.1 Въведение.....	11
1.1.2 Несигурност в икономиката	12
1.1.3 Кейнсианска несигурност	13
1.1.4 Несигурност на Найт	14
1.1.5 Алеаторна и епистемична несигурност	17
1.1.6 Дефиниция и класификация на несигурността за целите на икономическото прогнозиране.....	22
1.1.7 Заключение.....	24
1.2 Икономическо прогнозиране и развитие на вероятностното прогнозиране.....	26
1.2.1 Структурно макроикономическо прогнозиране.....	26

1.2.2	Неструктурно макроикономическо прогнозиране и прогнозиране на времеви редове.....	28
1.2.3	Прогнозиране с големи масиви от данни.....	32
1.2.4	Комбинация от прогнози.....	36
1.2.5	Интервално, квантилно и вероятностно прогнозиране.....	38
1.2.6	Заключение.....	54
Глава 2: Вероятностно прогнозиране с помощта на изкуствени невронни мрежи..... 56		
2.1	Мотивация.....	56
2.2	Генериране на вероятностни прогнози с изкуствени невронни мрежи.....	57
2.3	Количествено определяне на епистемичната несигурност в изкуствените невронни мрежи.....	67
2.4	Разделяне на алеаторната и епистемичната несигурност.....	72
2.5	Оценка на точността и референтни показатели.....	73
2.5.1	Показатели за точност.....	74
2.5.2	Референтни методи.....	74
2.5.3	Обяснимост.....	77
Глава 3: Приложения на дълбоката квантилна вероятностна регресия..... 79		
3.1	Прогнозиране на пандемичната рецесия през 2020 г. в малки отворени икономики.....	79
3.1.1	Въведение.....	79
3.1.2	Данни.....	81
3.1.3	Резултати.....	88
3.1.4	Дискусия.....	94
3.2	Вероятностно прогнозиране на цените на природния газ на Газовия Хъб Балкан с помощта на дълбоко самообучение.....	97
3.2.1	Въведение.....	97
3.2.2	Данни.....	99
3.2.3	Резултати.....	103
3.2.4	Дискусия.....	106
3.3	Разширени приложения: Измерване на алеаторната и епистемичната несигурност при прогнозиране на потребителската инфлация в България.....	108
3.3.1	Въведение.....	108
3.3.2	Данни.....	109
3.3.3	Резултати.....	112
3.3.4	Дискусия.....	116
Заключение.....119		
	Обобщение на резултатите.....	119
	Научни приноси.....	120

Стойност и оригиналност на изследването	121
Ограничения на изследването	122
Възможности за бъдещи изследвания	123
Библиография.....	124
Приложение А: Оптимизация на целевата функция и индикатори на точността.....	148
Приложение Б: Сравнение между разпледението от тип хиперболичен синус- хиперболичен аркуссинус и наклоненото t-разпределение	152
Приложение В: Списък на показателите, използвани в емпиричните изследвания	153
Приложение Г: Резултати от бутстрап на индикаторите на точност	155

Първата глава се състои от две части. Първата част е посветена на дефиницията и класификацията на икономическата несигурност за целите на икономическото прогнозиране. Тя разглежда в дълбочина класифицирането на несигурността на алеаторна и епистемична и начините за нейното количествено определяне. Втората част на първа глава представлява задълбочен литературен преглед на икономическото прогнозиране и неговото развитие през изминалия век. Главата завършва с преглед на различни методи, използвани за генериране, калибриране и оценка на вероятностни прогнози.

Във втора глава е създадена нова архитектура на невронна мрежа за вероятностно прогнозиране, наречена дълбока квантилна вероятностна регресия (DQPR), базирана на дълбоко самообучение и вдъхновена от доказана техника от икономическата литература. Разгледани са няколко алтернативни архитектури и са проведени емпирични тестове за оценка на точността и ефективността на обучението на предложения модел. Направен е преглед на бейсовите методи в сферата на дълбокото самообучение и е представен метод за декомпозиция на алеаторната и епистемичната несигурност. Накрая е избран подход за оценка на предложения модел спрямо няколко еталона и са обсъдени начини за извършване на анализ на чувствителността.

Третата и последна глава е посветена на конкретни приложения на предложения модел DQPR в три отделни емпирични изследвания. Първият казус е свързан с прогнозиране на свързаните с пандемията рецесии в България, Литва, Естония и Румъния. Предложената рамка е сравнена с линейна версия на същия модел и предимствата на използването на дълбоко обучение са демонстрирани в емпирично упражнение.

Второто проучване показва как предложената рамка може да се приложи за прогнозиране на цените на природния газ на Газовия Хъб Балкан, като се използват данни от водещия европейски газов хъб TTF в Нидерландия.

Резултатите от работата на предложената рамка се сравняват с няколко метода от статистиката и машинното самообучение и се демонстрира, че тя превъзхожда референтните модели.

Третият казус демонстрира възможността за конструиране на ветрилообразни графики на инфлацията с помощта на предложената рамка - инструмент, който редовно се използва от централните банки по света. Освен че се конструират вероятностни прогнози на инфлацията в България за различни прогнозни хоризонти, се демонстрира и как на практика могат да се декомпозират алеаторната и епистемичната несигурност.

Накрая в заключенията се обобщават приносите на изследването, неговите ограничения и възможностите за бъдеща работа по темата.

III. Основни резултати от дисертацията

Глава 1: Икономическо прогнозиране и несигурност

Несигурност - дефиниция и класификация за целите на икономическото прогнозиране

Концепцията за несигурността е тема от голям интерес за учените както в природните, така и в социалните науки. То играе важна роля в различни области и по този начин с течение на времето терминът "несигурност" е приел различни значения. Първите познати опити за дефиниране на несигурността и несигурността са дело на гръцките философи от Атинската школа (Bernstein, 1996). Древногръцката дума εἰκος (ейкос), която може да се преведе като вероятно или правдоподобно, е дефинирана от Сократ като "подобие на истината". Аристотел също теоретизира по темата за вземането на решения в своята „*Никомахова етика*“, но той не се задълбочава в концепцията за несигурността, а по-скоро приема късмета или случайността за даденост. От друга страна, макар игрите на късмета да изглеждат толкова стари, колкото и историята, с някои ранни известни примери от Древен Египет, датиращи от 3500 г. пр.н.е., едва през Ренесанса хазартът е използван като основа за изучаване на несигурността (Bernstein, 1996).

През 1654 г. френският благородник Шевалие дьо Мере предизвиква известния математик Блез Паскал да реши загадка, която обърква математиците в продължение на около двеста години, когато е поставена от монаха Лука Пачоли. Загадката се състояла в това как да се раздели печалбата от незавършена игра на късмета между двама играчи, докато единият от тях е на печалба. С помощта на друг блестящ математик, Пиер дьо Ферма, Паскал полага основите на това, което днес познаваме като теория на вероятностите. Вследствие на това различни велики мислители и учени продължават да изследват и преразглеждат концепцията за несигурността, като Бейс, Бернули и Галтон, назовавайки само някои от тях. В началото на XX век концепцията за несигурността вече играе

решаваща роля в анализа в различни области - от физиката до психологията, а това е и времето, когато някои от най-изтъкнатите икономически мислители поставят фундаментални основи на концепцията за риска и несигурността.

Изследванията, насочени към моделиране и прогнозиране на несигурността, могат да страдат от неяснота и липса на прецизност, без да се дефинира ясно понятието за несигурност и ако терминът се използва като саморазбиращ се. Настоящият текст има за цел да създаде работна дефиниция и класификация на несигурността за целите на икономическото прогнозиране. Това е необходимо, за да се постигне общо разбиране на термина, да се намали семантичната двусмисленост и да се определи ясно разграничение, що се отнася до количествената оценка на прогнозната несигурност. Напоследък в областта на инженерните науки и машинното самообучение нараства популярността на разделянето на несигурността на алеаторна и епистемична. Алеаторната несигурност се отнася до стохастичността присъща на процесите в реалност или тяхното измерване, докато епистемичната несигурност се отнася до ограниченията на знанията на наблюдателя. Практичността и стремежът към яснота и недвусмислено разделение правят тази класификация привлекателна и тя се счита за подходяща в контекста на икономическото прогнозиране. Ето защо два фундаментални източника за несигурността на Джон Мейнард Кейнс и Франк Х. Найт, които определят и изследват понятието в икономическата литература, са разгледани от гледна точка на класификацията на несигурността на алеаторна и епистемична. Вследствие на това се обсъждат в детайл понятията за алеаторна и епистемична несигурност, възможните двусмислия между понятията и взаимодействието между тях. Накрая се излагат работна дефиниция и класификация на несигурността, които се допълват за практически цели в контекста на икономическото прогнозиране.

За известно време несигурността не е имала място в икономиката (Davidson, 1999). Класическата икономическа теория е била заинтересована от икономически агенти, притежаващи съвършена информация за резултатите от своите решения, и несигурността просто се е пренебрегвала. През 1921 г. са публикувани два фундаментални труда от двама израстващи икономисти, които в крайна сметка стават основатели на две известни икономически школи: Джон Мейнард Кейнс публикува своята дисертация за теорията на вероятностите, а Франк Х. Найт също публикува преработен вариант на своята дисертация, който се занимава с несигурността и преценката. Тези двама съвременни мислители и техните фундаментални трудове поставят основите на това, което по-късно се превръща в две отделни школи на икономическата мисъл - Кейнсианската школа в макроикономиката (Snowdon and Vane, 2015) и Чикагската школа в микроикономиката (Emmett, 2009).

На пръв поглед изглежда, че в тези основополагащи трудове е разработена сходна теория за несигурността, поради което някои я наричат "концепцията за несигурността на Найт-Кейнс" (напр. Davidson, 1972; Hodgson, 2011). Въпреки това

Packard et al. (2021), които са направили критичен преглед на историческите документи и трудовете на Кейнс и Найт, твърдят, че в основата си двамата мислители се различават по своите политически възгледи, научна епистемология, онтологични убеждения и в крайна сметка по възгледите си за несигурността. Авторите смятат, че в исторически план теориите на Кейнс и Найт за несигурността и политическите им философии като цяло са били погрешно хомогенизирани, което е в рязък контраст с различията в школите, на които всеки от тях е поставил основите. Макар да е безспорно, че между техните концепции за несигурността има сходства, съществуват и нюансирани различия, които са ги довели до различни изводи относно естеството на несигурността и начина, по който човек трябва да се справя с нея.

Кейнс е бил обективист, позитивист и детерминист, който е вярвал в идеята за обективна детерминистична реалност, която трябва да се изучава чрез емпиризм и рационализъм. От тази гледна точка несигурността, произтичаща от ограничеността, невежеството и ирационалността на даден субект, може да бъде намалена чрез систематично научно изследване и постоянно търсене на нови доказателства. Подобен възглед обаче би отхвърлил идеята, че някои аспекти на реалността могат да бъдат изначално неопределени дори в случай на свършено знание.

Според Packard et al. (2021) възгледът на Найт за несигурността, в светлината на неговия мироглед и особено на противопоставянето му на позитивизма в икономическия анализ, е алеаторен - свързан с присъщата на процесите стохастичност и непредсказуемост, която също така е не подлежи на редуциране чрез натрупване на нови доказателства. Други, сред които Фридман (2007), тълкуват несигурността на Найт като епистемична и по този начин сходна с възгледа на Кейнс - тълкуване, което доминира мейнстрийм икономиката. Самият Найт (1921) обаче многократно намеква, че в икономиката има "по-голям дял фактори ... от променлив и случаен вид", и заявява, че "това е свят на промени, в който живеем, и свят на несигурност".

Изглежда, че Найт е вярвал, че несигурността е присъща на реалността, което говори за несигурност в алеаторен смисъл. Въпреки това той често споменава субективното, психологическото и знанието на индивида, което означава, че възприема несигурността и в епистемичен смисъл. По собствените му думи той изглежда разширява възгледа си в епистемичен смисъл не само до бъдещето, но и до настоящето, което изглежда съвпада с идеи от психологията. Може би с отхвърлянето на позитивизма и третирането на социалните науки и в частност на икономиката като точна наука Найт е постигнал по-широк и всеобхватен поглед върху несигурността в сравнение с Кейнс, който е вярвал в предвидимостта на човешкото поведение и е възприемал несигурността почти изключително като епистемична по своя характер.

Въпреки че определението и дихотомията на Франк Х. Найт за риск и несигурност остават изключително влиятелни в икономиката, прякото им приложение в икономическото прогнозиране изглежда ограничено от съвременна гледна точка. Използването на класификацията на Найт в контекста на прогнозирането може да бъде извършено само ex-post, след реализирането на дадено събитие, тъй като към момента на прогнозиране експертът не би могъл да определи пред какъв тип ситуация е изправен. Следователно класификацията на Найт все още е полезна в едно второ време, но има ограничена стойност към момента на прогнозиране. Възможно е дори да се каже, че към този първоначален момент прогнозиците винаги действат така, сякаш се намират в ситуация обуслована от риск, в която е известна пълната информация за възможните резултати и свързаните с тях вероятности. Ето защо е уместно да се обърнем към една по-съвременна класификация на несигурността, която вече беше спомената, но не е и дискутирана в детайл - разделянето на несигурността на алеаторна и епистемична. Тази алтернативна класификация се счита за по-практична в контекста на икономическото прогнозиране, тъй като може да се прилага както в момента на прогнозиране, така и в ретроспекцията, и позволява по-подробен количествен анализ.

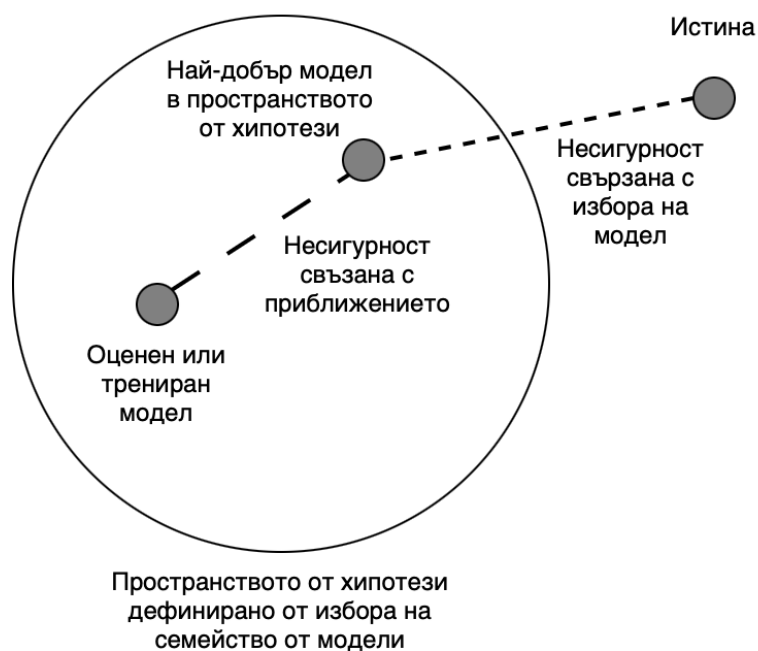
Разделянето на несигурността на алеаторна и епистемична изглежда произхожда от областта на инженерните науки (Hora, 1996; Faber, 2005; Kiureghian and Ditlevsen, 2009), въпреки че е трудно да се намери научно изследване, в което да се споменава произходът на термините. Поради своята практичност той се използва в областта на компютърните науки и машинното самообучение (Dutta, 2013; Shaker и Hüllermeier, 2020; Hüllermeier и Waegeman, 2021; Lai и др. 2022), а също и в икономиката, макар и рядко (Dequech, 2004; Packard и Clark, 2020; Curto, Acebes и González-Varona, 2022).

Алеаторната (или статистическата) несигурност се отнася до несигурността, свързана с присъщата стохастичност или случайност в процесите на генериране на данни или в резултата от експеримента (Hora, 1996; Hüllermeier и Waegeman, 2021). Терминът идва от латинската дума alea, която означава кост или зар, тъй като костите са били използвани като зарове в хазартните игри в миналото (Lewis and Short, 1879). Предполага се, че при настоящите знания за даден процес на генериране на данни съществува степен на несигурност, която не може да бъде намалена чрез натрупване на повече доказателства или промяна или усъвършенстване на статистическия модел на дадения процес. Тази несигурност обаче може да бъде идентифицирана и количествено определена. Практичността на концепцията за алеаторна несигурност е, че тя може да бъде обоснована въпреки онтологичния възглед на нейния ползвател. Тя се вписва и може да се използва в контекста както на детерминизма, така и на индетерминизма.

От друга страна, думата "епистемичен" произлиза от старогръцката дума ἐπιστήμη (епистѐми), която означава знание. Епистемичната несигурност възниква от липсата на знания на наблюдателя, вземащия икономически решения или

прогностика по отношение на процеса на генериране на данни (Hüllermeier and Waegeman, 2021). Епистемичната несигурност съвпада до голяма степен с възгледа на Кейнс за несигурността, която може да бъде намалена чрез натрупване на по-голяма доказателствена тежест или знания за системата като цяло. Така, за разлика от алеаторната несигурност, основната характеристика на епистемичната несигурност е, че тя принципно може да бъде намалена (Hora, 1996). Ако тази концепция се приложи към задача за прогнозиране, епистемичната несигурност може да се отнася до несигурността, свързана с избора на семейство статистически модели или модели за машинно самообучение, избрани за дадена задача, или с количеството налични данни. Човек може да намали тази несигурност, като избере по-добър модел на процеса на генериране на данни или като събере повече подходящи данни, за да оцени по-точно параметрите на модела.

Фигура 1: Видове епистемична несигурност




Източник: Автор, въз основа на Hüllermeier и Waegeman (2021)

Епистемичната несигурност може да бъде допълнително сведена до поне още две подкатегории: несигурност произтичаща от избора на модела и несигурност свързана с приближението (Hüllermeier и Waegeman, 2021), както е показано в Фигура 1. Несигурността свързана с приближението се отнася до несигурността около изчислените параметри на модела, и може да бъде изразена като разлика между избраната хипотеза или модел и оптималната хипотеза в рамките на избраното пространство от хипотези (семейство от модели). Несигурността произтичаща от избора на модела се отнася до избора на пространството на хипотезите или семейството от модели като цяло и може да се изрази като разлика

между истината (или статистическия модел на популацията) и оптималната хипотеза в рамките на пространството на хипотезите. Ако става въпрос за задачата на икономическото моделиране или прогнозиране, несигурността на модела се отнася както до избора на семейство от модели, така и до използваните за моделиране независими променливи. Например използването на линеен модел при моделиране на квадратична зависимост може да бъде източник на епистемична несигурност на подкатегорията на модела. Отклонението от оценката в следствие на липсваща променлива също може да бъде източник на епистемична несигурност от същия вид. Пример за Несигурност свързана с приближението в контекста на проста линейна регресия би била несигурността около регресионния коефициент, която обикновено се изразява чрез доверителен интервал. Според Hüllermeier и Waegeman (2021 г.), при наличие на последователна оценка, асимптотично може да се елиминира несигурността свързана с приближението чрез увеличаване на броя на наблюденията.

Фигура 2: Алеаторна и епистемична несигурност



Източник: Автор, въз основа на Hüllermeier и Waegeman (2021)

Фигура 2 показва как епистемичната несигурност се различава от алеаторната несигурност в контекста на прост класификационен модел. От лявата страна, в точката, обозначена с въпросителен знак, прогнозата е алеаторно несигурна поради припокриването на двата класа в тази област около границата на решението. От дясната страна, точката, обозначена с въпросителен знак, е случай на епистемична несигурност, дължаща се на липсата на познания за параметъра на модела, което от своя страна се дължи на липсата на достатъчно данни.

Въз основа на обсъжданията дотук несигурността може да се определи като липса на сигурни познания или разбиране за изхода от дадена ситуация или събитие. Несигурността може да се счита за основна характеристика на бъдещето, но както

посочва Найт (1921), тя може да се отнася и за настоящето, особено когато става въпрос за сложни взаимодействия. Несигурността произтича както от стохастичността, присъща на средата като цяло или на даден процес на генериране на данни, така и от ограничените знания на наблюдателя или прогностика, който се опитва да моделира посочения процес на генериране на данни.

Когато се разглежда алеаторната несигурност, тя може да се изрази по следния начин. Първо и преди всичко, $\mathcal{D}^T = (Y, X, X_{T-h})$ е наборът от информация, с който разполага прогностика. Y е вектор на целевата променлива или зависимата променлива. X е вектор на факторите или независимите променливи до момент T и X_{T-h} е вектор на независимите променливи, които са налични след момента T , за да се генерират прогнози Y_{T-h} за прогнозен хоризонт с дължина h . Можем да измерим алеаторната несигурност по прост начин, като използваме безусловното или емпиричното разпределение на Y дадено с $f(Y)$. Това обаче позволява да се правят само наивни прогнози. Прогнозното разпределение $f(Y_{T+h}|\mathcal{D}^T)$ е това, което се нарича прогнозно разпределение, тъй като то описва разпределението на Y за бъдещи стойности и е условно спрямо набора от информация.

Ако приемем, че $f(Y_{T+h}|\mathcal{D}^T)$ е създадена с помощта на хипотеза или модел $H(\theta)$ с вектор от параметри θ , епистемичната несигурността свързана с приближението може да се дефинира като несигурността около параметрите, изразена чрез условното разпределение $f(\theta|\mathcal{D}^T)$. Както беше споменато по-рано, асимптотичното увеличаване на размера на информационното множество $N \rightarrow \infty$ по принцип ще елиминира тази несигурност свързана с приближението. Друг важен аспект на несигурността на апроксимацията обаче е оптимизацията на хиперпараметрите. При фиксирано пространство от хипотези оптимизирането на хиперпараметрите на алгоритъма за обучение може да намали разстоянието до оптималния модел в рамките на пространството от хипотези и по този начин да намали епистемичната несигурност свързана с приближението. Следователно два подтипа на несигурността свързана с приближението са свързаната с данните несигурност и свързаната с хиперпараметрите несигурност.

Като се има предвид простото определение, дадено по-горе, Фигура 3 представя класификацията на несигурността в контекста на задачата за икономическо прогнозиране.

Фигура 3: Класификация на несигурността при икономическото прогнозиране



Източник: Автор

Макар да изглежда, че предимството на вероятностните прогнози пред точковите прогнози е безспорно, важно е да се анализира несигурността според нейния източник. Hüllermeier и Waegeman (2021) твърдят, че анализът на несигурността "на ниво казус, вероятно е важен и практически по-подходящ от един вид средна точност или доверие, което често се съобщава в машинното самообучение". Те дават пример с медицинската диагностика, където пациентът би се интересувал от надеждността на прогнозата в неговия/нейния случай, а не от някаква средна мярка за надеждност на модела. Kull и Flach (2014 г.) също твърдят, че изчисляването на оценки за надеждност на всеки един случай е много по-силно доказателство в сравнение с генерирането на обобщена оценка за надеждност. Допълнителната информация, предоставена от количественото определяне на несигурността по този трансдуктивен начин, би повлияла и може би би подобрила вземането на решения поради по-голямата прозрачност и информационна стойност. Може да се види как този възглед може да се приложи и към икономическото прогнозиране, за да се осигури по-голяма информационна стойност при съобщаването на прогнозите.

В този критичен преглед теориите за несигурността на Кейнс и Найт бяха разгледани от гледна точка на класификацията на несигурността, която произлиза от инженерните науки и става доминираща в машинното самообучение. Нейната основна предпоставка е разделянето на несигурността като такава, присъща на средата или свързана с нейното измерване (алеаторна), и такава, произтичаща от ограниченията на прогнозиращия и неговите знания (епистемична). Поради практическото удобство и прозрачност на този подход към несигурността той е

възприет за задачата на икономическото прогнозиране. Тази класификация на несигурността е обогатена и адаптирана за контекста на икономическото прогнозиране и очертава подкласовете на алеаторната и епистемичната несигурност. В заключение се установява, че прогностикът не трябва да избягва оценката на несигурността и трябва да се опита да я декомпозира, за да увеличи информационната стойност на своите прогнози.

Икономическо прогнозиране и развитие на прогнозирането на плътността

Към края на XIX в. в областта на статистиката се наблюдава преход от точкови оценки към оценки на разпределението според Stigler (1975). Gneiting (2008) описва подобно преминаване на интереса от точкови прогнози към вероятностни прогнози в много области и икономиката не прави изключение. Прегледът на литературата по прогнозиране, направен от Diebold и Lopez през 1996 г., разкрива, че когато става въпрос за оценка на прогнозите, темата за оценка на точковите прогнози доминира в областта по това време. Малко статии са били фокусирани с оценката на прогнозните интервали (Chatfield, 1993; Christoffersen, 1998) или вероятностните прогнози (Wallis, 1993; Clemen et al., 1995). Нещо повече, Diebold et al. (1998) смятат, че до появата на количествените финанси и управлението на риска е имало малко търсене за интервални или вероятностни (плътностни) прогнози в областта на икономиката. Практиката на прогнозиране сама по себе си е опит да се изследва едно несигурно бъдеще, а вероятностните прогнози, изразени като вероятностни разпределения върху очакваните бъдещи реализации, са основен начин за измерване на степента на несигурност.

Понастоящем в областта на прогнозирането най-простият начин за измерване на несигурността, свързана с дадена прогноза, е чрез доверителни и прогнозни интервали. Chatfield (1993 г.) описва интервалите на прогнозите като състоящи се от горна и долна граница, свързани с предварително определена вероятност. Тези горни и долни граници определят диапазона, в който би попаднала бъдещата стойност на случайната променлива с определено ниво на достоверност. Hansen (2006 г.) уточнява, че интервалните прогнози често се изграждат около точкови прогнози като допълнителна мярка за несигурност. Всъщност, тъй като много методи за прогнозиране са пригодени за генериране на точкови прогнози, изчисляването на интервалите е лесен начин за количествено определяне на несигурността около тези прогнози.

Квантилната регресия е друга концепция, която първоначално датира от 18-ти век, въведена наскоро отново от Koenker и Bassett (1978 г.) и се прилага в икономическия анализ в различни изследвания. Fitzenberger, Koenker и Machado (2002 г.) представят редица икономически изследвания, в които е използвана квантилна регресия. Според тях едва през 90-те години на миналия век техниката придобива по-голяма популярност сред икономистите и иконометриците. Някои от забележителните изследвания, които авторите представят в книгата *Economic Application of Quantile Regression* (2002), са Fitzenberger et al. (2001), които изследват

структурата на заплатите в Западна Германия, García et al. (2001), които използват квантилна регресия, за да изследват разликите в заплатите на мъжете и жените в Испания, и Buchinsky (2001), който анализира възвръщаемостта на образованието сред жените в САЩ.

Както показват Koenker и Bassett (1978), задачата за сортиране може да се превърне в оптимизационна задача. Точно както намирането на средната стойност на извадката може да се извърши чрез минимизиране на сумата на квадратните грешки, намирането на медианата може да се достигне чрез минимизиране на сумата на абсолютните грешки. Koenker и Bassett (1978 г.) доразвиват темата, за да покажат, че една целева функция асиметрична спрямо грешките, която дава различни тежест за положителните и отрицателните остатъци, може да се използва за оценката на всеки квантил за дадена извадка. Решаване на следното уравнение (1) дава τ -тия квантил като решение:


$$\min_{\xi \in \mathbb{R}} \sum_{i=0}^n \rho_{\tau}(y_i - \xi) \quad (1)$$

Къде: $0 < \tau < 1$ и $\rho_{\tau}(\cdot)$ е наклонената (квантила) функция на абсолютните стойности, която може да се види във Фигура 4, за извадка с размер n . В това уравнение, ако τ се зададе стойност, равна на 0.5, уравнението ще даде медиана. Следователно, ако скаларът ξ в уравнението (1) се замени с параметрична функция $\xi(x_i, \beta)$ и τ е равна на 0.5, може да се получи оценка на условната медианна функция.

$$\min_{\xi \in \mathbb{R}} \sum_{i=0}^n \rho_{\tau}(y_i - \xi(x_i, \beta)) \quad (2)$$

Задаване на τ на различни стойности ще доведе до оценка на различни условни квантилни функции.

Фигура 4: Функция на наклонената абсолютна стойност



Източник: Автор, въз основа на Koenker (2005)

По принцип бихме моделирали връзката между условния квантил на y_{t+h} и вектора от независими променливи X и по желание техните минали стойности, за даден период от време t и прогнозен хоризонт h . За да оценим квантовата регресия на y_{t+h} върху X , регресионните коефициенти β_τ за даден τ се избират така, че да минимизират претеглената абсолютна стойност на грешките:

$$\hat{\beta}_\tau = \operatorname{argmin}_{\beta_\tau \in \mathbb{R}^k} \sum_{t=1}^{T-h} (\tau \cdot 1_{(y_{t+h} \geq X\beta_\tau)} |y_{t+h} - X\beta_\tau| + (1 - \tau) \cdot 1_{(y_{t+h} < X\beta_\tau)} |y_{t+h} - X\beta_\tau|)$$

(3)

където $\mathbf{1}(\cdot)$ е индикаторната функция, която разделя отрицателните и положителните грешки, а T е общата дължина на времевия ред. Изходната стойност от модела е квантилът на y_{t+h} в зависимост от входните данни на модела X :

$$\hat{Q}_{y_{t+h}|X}(\tau|X) = X\beta_\tau$$

(4)

Този метод позволява да се оцени квантилен регресионен модел за оценка на произволен квантил, обусловен от независимите променливи. Въпреки това, ако човек иска да оцени няколко различни квантила, може да се сблъска с т.нар. проблем на пресичането, с който множество учени са се сблъскали и са се опитвали да се справят по един или друг начин (вж. Koenker, 1984; Cole and Green, 1992; He, 1997; Bondell et al., 2010; Rodrigues and Pereira 2020). Сред по-интересните решения са тези, предложени от Bondell et al. (2010) и Rodrigues and Pereira 2020.

В основополагаща статия Adrian et al. (2019 г.) използват двустъпкова процедура за конструиране на условни квантили с помощта на квантилен регресионен модел и впоследствие оценяват вероятностно разпределение към оценените квантили. Авторите изследват условното разпределение на растежа в САЩ с акцент върху финансовите условия и тяхната динамика по време на икономически рецесии. Авторите установяват няколко стилизирани факта относно условното разпределение на растежа за САЩ, сред които силна отрицателна корелация между условната средна стойност и дисперсията и значителна връзка между настоящите финансови условия и бъдещите промени в долната част на условното разпределение. Подобни заключения са потвърдени и от De Santis и Van der Veken (2020 г.), които извършват подобен анализ, включващ данни от началото на 2020 г. и отделен набор от данни, обхващащ периода на пандемията от испански грип в редица държави. Figueres and Jarociński (2020), потвърждават същите стилизирани факти, установени от Adrian et al. (2019) за еврозоната.

Квантилите на условното разпределение на растежа на БВП в тази рамка се изразяват като функции на наблюдаваните независими променливи. След като се

генерират условните квантили, към тях може да се приложи функция на вероятностно разпределение, за да се създаде прогнозно разпределение. Adrian et al. (2019) предлагат за тази цел да се използва наклонено t-разпределение. За да се оценят четирите параметъра, свързани с наклоненото t-разпределение, проблемът може да се формулира като оптимизационна задача на най-малките квадрати, като се използват оценените условни квантили¹ и обратната кумулативна вероятностна функция:

$$\{\hat{\mu}_{t+h}, \hat{\sigma}_{t+h}, \hat{\nu}_{t+h}, \hat{\alpha}_{t+h}\} = \operatorname{argmin}_{\mu, \sigma, \nu, \alpha} \sum_{j=1}^J \left(\hat{Q}_{y_{t+h}|X}(\tau_j|X) - F^{-1}(\tau_j; \mu, \sigma, \nu, \alpha) \right)^2$$

(5)

където $\hat{\mu}_{t+h} \in \mathbb{R}$ (средна стойност или промяна на местоположението), $\hat{\sigma}_{t+h} \in \mathbb{R}^+$ (стандартно отклонение или параметър на дисперсията), $\hat{\nu}_{t+h} \in \mathbb{R}$ (параметър на наклона) и $\hat{\alpha}_{t+h} \in \mathbb{R}^+$ (куртоза или параметър на теглото на опашките). F^{-1} е обратната кумулативна функция на разпределение и $\hat{Q}_{y_{t+h}|X}(\tau_j|X)$ е оцененият квантил на y_{t+h} за даден τ и условен на X . Този метод може да се използва за оценка на прогнозното разпределение въз основа на условните квантили, както и на емпиричните или наблюдаваните квантили на действителния растеж на БВП.

Пълната вероятностна прогноза (или прогнозната плътност) е прогноза, изразена като вероятностно разпределение, а не като единична стойност, която би се считала за точкова прогноза. Точковите прогнози често са централна характеристика на вероятностно разпределение като условната средна стойност или условната медиана, които могат да бъдат получени чрез оптимизиране на функциите на загубите съответно на средните квадратни грешки и средните абсолютни грешки. Плътностните прогнози могат да бъдат изразени като параметрите, които описват вероятностното разпределение, или както формално се наричат моментите на разпределението. За много семейства вероятностни разпределения, като нормалното наклонено разпределение, наклоненото t-разпределение и разпределението Хиперболичен синус – Хиперболичен аркуссинус, те включват средната стойност (или местоположението), дисперсията (или размер), наклон и куртозата (последните два понякога се наричат параметри на формата). В контекста на времевите редове, който е преобладаващ в икономиката и иконометрията, прогнозното разпределение за хоризонт h се изразява като прогнозни моменти на вероятностно разпределение за всяка стъпка във времето в рамките на хоризонта.

¹ Квантилите .05, .25, .75 и .95 се използват за оценка на условното разпределение.

Следвайки Bassetti et al. (2019), основите на прогнозирането на плътността могат да се установят, като се използва контекстът на множествен линеен регресионен модел без свободен член за удобство:

$$y_t = X_t^T \beta + \varepsilon_t$$

(6)

където $t = 1, \dots, T$ и $\varepsilon_t \sim i.i.d.(0, \sigma^2)$. β е $(m \times 1)$ вектор на коефициентите, σ^2 е дисперсията на члена на грешката ε_t , X_t е $(m \times 1)$ вектор на ковариатите или независимите променливи, които могат да включват екзогенни променливи z_t и минали стойности на зависимата променлива, $Y_{t-p}, p > 0$. Директен метод за изчисляване на вероятностната прогноза е да се направи допускане за разпределението за грешките и да се игнорира несигурността свързана с параметрите. Обичайното допускане е това за нормалност - $\varepsilon_t \sim N(0, \sigma^2)$. Това би отчело алеаторната несигурност, но би игнорирало епистемичната такава. Прогнозата за плътността на h -стъпка напред, обусловена от наличната информация в информационната съвкупност до момента T , би била:

$$f(Y_{T+h} | \mathcal{D}^T) = N(X_T^T \hat{\beta}, \hat{\sigma}^2)$$

(7)

където $\hat{\beta}$ и $\hat{\sigma}^2$ могат да бъдат изчислени аналитично или числено. В този случай дисперсията е фиксирана за дадена оценка на модела.

Съществуват многобройни методи за генериране на вероятностни прогнози, но няма цялостен набор от инструменти за това. В икономиката моделът на авторегресивната условна хетероскедастичност (ARCH), основополагащ труд в икономиката на Engle (1982 г.), има за цел да моделира и прогнозира волатилността на фондовия пазар и все още се използва широко при моделиране на условните дисперсии. Различен подход за моделиране на всички моменти от разпределението на целевата променлива се определя от обобщените адитивни модели за местоположение, мащаб и форма - GAMLSS (Rigby and Stasinopoulos, 2005). В този модел моментите на дадено разпределение се моделират чрез отделни уравнения, които се оценяват съвместно чрез максимално правдоподобна оценка или чрез Байесови методи. В областта на машинното самообучение и по-конкретно на дълбокото самообучение са предложени множество подходи, основани на изкуствени невронни мрежи. Някои забележителни примери са Gal и Ghahramani (2016), които предлагат теоретична рамка, наречена Monte Carlo dropout, Salinas и съавтори (2019) представят модела DeepAR, който представлява авторегресионна рекурентна невронна мрежа, която извършва вероятностно прогнозиране и е специално пригодена за прогнозиране на голям брой времеви редове, а Alexandrov и съавтори (2020) представят своя пакет за прогнозиране за

Python, наречен GluonTS, използващ трансформаторни и wavenet архитектури за вероятно прогнозиране.

При вероятностното прогнозиране задачата за оценяване на прогнозата е трудна, тъй като трябва да се сравнят прогнозираните разпределения с една-единствена стойност на реализираната истина. Поради това многобройни изследвания са насочени към разработване и усъвършенстване на методи за оценка на прогнозата за плътността. Както Gneiting et al. (2007) определят два отделни аспекта, в които трябва да се оценява прогнозата за плътността - калибрация и острота. Калибрацията се отнася до статистическата съгласуваност между вероятностните прогнози и наблюдаваните данни, докато остротата се разбира като концентрация на прогнозните разпределения. По-високата концентрация на вероятностните прогнози е по-добра, при условие че се калибрирани. Както посочват Mitchell и Wallis (2011 г.), остротата е свойство само на прогнозните разпределения, докато калибрацията е свойство на двойките прогноза-наблюдение.

Правилата за оценка дават числени стойности на вероятностните прогнози въз основа на прогнозното разпределение и реализацията на прогнозираната променлива. Те удобно обобщават резултатите от прогнозирането, когато се оценява качеството на вероятностната прогноза. Такива правила за оценка включват логаритмичната оценка и непрекъснатата ранжирана вероятностна оценка (CRPS). Струва си обаче да се оцени и точността на централните характеристики на прогнозните разпределения, като средната стойност и медианата. Това може да се извърши, като тези централни характеристики се третират като точкови прогнози. Следователно традиционните показатели за точност на точковите прогнози, като средна квадратична грешка, корен на средната квадратична грешка или средна абсолютна грешка, са напълно валидни в това отношение. За обсъждане на темата за оценка на точкови прогнози вижте Gneiting (2011).

Проследяването на историческото развитие на икономическото прогнозиране позволява да се разбере разделението между структурното и неструктурното моделиране и прогнозиране. Първото се ръководи и е силно подкрепено от теорията и често се използва за симулации на сценарии и тестване на теоретични допускания, докато второто се оказва по-практично и точно в професията на прогностика. В огромната по обем литература са предложени множество неструктурни методи и процедури за генериране на прогнози за времеви редове, а многобройни изследвания се занимават със свойствата на тези методи и тяхната оценка. Отскоро са разработени и усъвършенствани много нови методи за вероятно прогнозиране поради очевидната необходимост от количествена оценка на несигурността, свързана с прогнозите.

В научната литература като цяло се наблюдава ясна тенденция към вероятно прогнозиране поради очевидните предимства в сравнение с точковите прогнози,

обсъждани още в края на 60-те години на 20-ти век, но още по-често след 2000 г. Много изследвания в областта на икономиката и машинното самообучение все още се фокусират върху точковото прогнозиране. Въпреки това много изследователи, както и институции като централните банки, вече са признали предимството на използването на прогнози по плътност. От друга страна, инструментите за генериране и оценяване на прогнози за плътността все още не са толкова достъпни и утвърдени, колкото инструментите, които сега се използват широко за точково прогнозиране.

Глава 2: Вероятностно прогнозиране с помощта на изкуствени невронни мрежи

Методите, базирани на квантилната регресия, често се използват за интервално или напълно вероятностно прогнозиране. Съществува обширна и нарастваща икономическа литература, която се занимава с квантилните методи, тяхната оценка и приложения към различни задачи за прогнозиране. От друга страна, интересни разработки по същата тема има и в областта на машинното самообучение. Напоследък областта на машинното самообучение като цяло, и по-специално подобластта на дълбокото самообучение, е източник на много иновации. Дълбокото самообучение е подобласт, свързана с изкуствените дълбоки невронни мрежи. Ето защо е съвсем естествено тези иновации да бъдат пренесени и приложени в областта на икономиката. Вижте Cook and Hall (2017) за обширен преглед на различни архитектури на изкуствени невронни мрежи в контекста на икономическото прогнозиране.

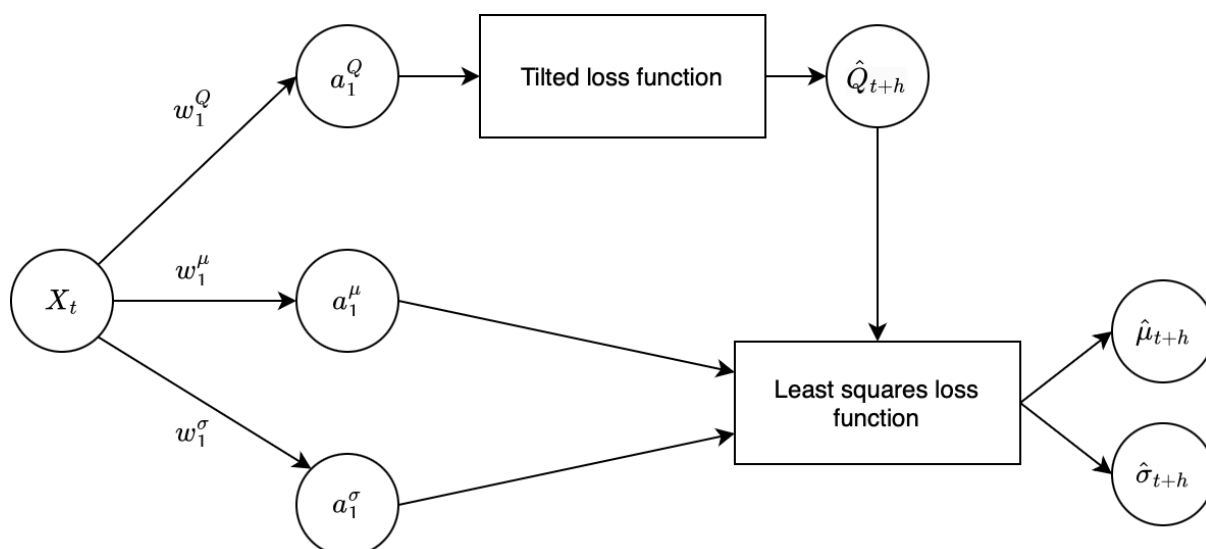
В текущата дисертацията е предложена нова архитектура на изкуствена невронна мрежа за целите на вероятностното прогнозиране на времеви редове, която се основава на оценка на условни квантили и прогнозни разпределения. Тя е вдъхновена от двустъпковата процедура, използвана в основополагащата статия на Adrian et al. (2019), но реализира оценка на условните квантили в рамките на архитектура на невронна мрежа, използва симултантна оценка на квантилите подобно на Rodrigues and Pereira (2020) и извежда прогнозни плътности в една стъпка на извод.

Мотивацията на това предложение е да се решат два въпроса. Първо, от практическа гледна точка е удобно двата етапа на процедурата, описана по-горе, да се съдържат в един модел. Едновременното оценяване на произволен брой условни квантили елиминира необходимостта от оценяване на отделна квантилна регресия за всяко квантилно ниво. Както е разгледано по-долу, по този начин се решава прословутият проблем с пресичането на квантилите. От друга страна, удобно е прогнозното разпределение да се оценява в една стъпка вместо в две отделни стъпки. На второ място, в сравнение с други вероятностни модели, които оценяват директно параметрите на прогнозното разпределение, може да се твърди, че този подход е по-обясним и прозрачен. Всяка промяна в параметрите на

дисперсията или формата може да бъде свързана с наблюдаваното поведение на квантилите. Също така всяка промяна в квантилите може да бъде обяснена чрез връзката им с избраните предиктори.

За да се оценят едновременно условните квантили и изходните прогнозни разпределения, архитектурата на мрежата зависи от използването на две целеви функции – квантилна целева функция, използвана за оценяване на квантилите, и функция на най-малките квадрати за оценяване на крайното прогнозно разпределение. Тази нова архитектура се нарича дълбока квантилна вероятностна регресия или накратко DQPR. Най-простата версия на предложената архитектура би включвала оценка на един квантил (например медианата) и едновременна оценка на прогнозна плътност, следваща нормалното разпределение, както се вижда в Фигура 5.

Фигура 5: Опростен вариант на DQPR



Източник: Автор

Тук X_T е наборът от независими променливи или регресори, като за тази формулировка се приема, че той съдържа само първия лаг на целевата променлива. Следователно, X_t е вектор с размер $(n \times m)$, където n е броят на наблюденията, m е броят на регресорите, който в този случай е равен на 1. y е вектор с размер $(n \times 1)$. Мрежата се дефинира от следните уравнения по време на извода:

$$\hat{Q}_{t+h} = a_1^Q = g(X_t w_1^Q + b_1^Q)$$

(8)

$$\hat{\mu}_{t+h} = a_1^\mu = g(X_t w_1^\mu + b_1^\mu)$$

(9)

$$\hat{\sigma}_{t+h} = a_1^\sigma = g(X_t w_1^\sigma + b_1^\sigma)$$

(10)

Къде: a_1^Q , a_1^μ , и a_1^σ са активациите, които са еквивалентни на резултатите на невронната мрежа - \hat{Q}_{T+h} което е условната медиана, $\hat{\mu}_{T+h}$ условната средна стойност на прогнозната плътност и $\hat{\sigma}_{T+h}$ условната дисперсия на прогнозната плътност. $g()$ е произволна активационна функция, която в този случай е линейна активация или с други думи, няма преобразуване на произведението от входящите данни и теглата. Теглата w_1^Q , w_1^μ , и w_1^σ са вектори с размер $(m \times 1)$ и $b_1^Q, b_1^\mu, b_1^\sigma$ са свободените членове, които са скалари.

Квантилната целева функция (известна също като флипер функция или наклонена функция), използвана за оценка на един условен квантил, се определя от:

$$QL = \sum_{t=1}^{T-h} (\tau \cdot \mathbf{1}_{(y_{t+h} \geq X_T w_1^Q)} |y_{t+h} - X_t w_1^Q| + (1 - \tau) \cdot \mathbf{1}_{(y_{t+h} < X_T w_1^Q)} |y_{t+h} - X_t w_1^Q|)$$

(11)

Къде: $\mathbf{1}()$ е индикаторната функция, използвана за разделяне на отрицателните и положителните остатъци. В случай че има няколко квантила, които представляват интерес, нека $\{\tau_j\}_{j=1}^J$ да бъде набор от J квантилни нива.

Един от начините да се оценят различните условни квантили е да се приложи квантилна регресия за всяко ниво. Това е не само неефективно, но може да доведе и до известния проблем с пресичането, който често се среща при квантилните регресии (Rodrigues and Pereira, 2018) Квантилната целева функция може да бъде обобщена за случая на множество квантилни нива, за да отразява сумата от индивидуалните функции на загубите на различните квантилни нива.

$$QL = \sum_{j=1}^J \sum_{t=1}^{T-h} (\tau_j \cdot \mathbf{1}_{(y_{t+h} \geq X_T w_1^{Q_j})} |y_{t+h} - X_t w_1^{Q_j}| + (1 - \tau_j) \cdot \mathbf{1}_{(y_{t+h} < X_T w_1^{Q_j})} |y_{t+h} - X_t w_1^{Q_j}|)$$

(12)

За да се справи изрично с проблема с пресичането, Bondell et al. (2010) предлагат да се добави допълнителен термин, който тук ще се нарича загуба от пресичане:

$$CL = \sum_{j=1}^{J-1} \max(0, X_t w_1^{Q_{\tau}} - X_t w_1^{Q_{\tau+1}})$$

(13)

В тази формулировка, ако по-ниският квантил има стойност, по-голяма от по-високия квантил, загубата от пресичане ще има стойност на тяхната разлика, в противен случай тя ще има стойност нула. Следователно този допълнителен член може да бъде добавен към квантилната целева функция, дефинирана по-горе.

И накрая, целевата функция по метода на най-малките квадрати, която отговаря за оценката на параметрите на прогнозното разпределение, е следната:

$$LSL = \sum_{j=1}^J (\hat{Q}_{y_{t+h}|X}(\tau_j|X_t) - F^{-1}(\tau_j; \mu, \sigma))^2$$

(14)

където $\hat{\mu}_{t+h} \in \mathbb{R}$ (средна стойност или промяна на местоположението), $\hat{\sigma}_{t+h} \in \mathbb{R}^+$ (стандартно отклонение или параметър на мащабиране). F^{-1} е обратната кумулативна функция на разпределение и $\hat{Q}_{y_{t+h}|X}(\tau_j|X)$ е оцененият квантил на y_{t+h} за даден τ и условно на X_t . Ако се използва четирипараметрично семейство на разпределение като разпределението на Хиперболичен синус – Хиперболичен аркуссинус, целевата функция ще бъде разширена по следния начин:

$$LSL = \sum_{j=1}^J (\hat{Q}_{y_{t+h}|X}(\tau_j|X_t) - F^{-1}(\tau_j; \mu, \sigma, \nu, \alpha))^2$$

(15)

където $\hat{\nu}_{t+h} \in \mathbb{R}$ (параметър на наклона) и $\hat{\alpha}_{t+h} \in \mathbb{R}^+$ (параметър на куртозата или теглото на опашките).

Предложената архитектура на невронната мрежа може да бъде обучена (оценена) чрез минимизиране на следната „обща“ целева функция:

$$TL = QL + CL + LSL$$

(16)

Може да се модифицира функцията, като се претеглят нейните компоненти с определени тегла. Тези тегла могат да бъдат фиксирани по време на обучението или динамични с помощта на произволно правило. Например това, което беше тествано на практика, е квантилна целева функция с допълнителен член за пресичане да има по-високо тегло през първите 70% от епохите на процеса на обучение и след това да се намали теглото им през последните 30% от епохите. Такава модификация би изглеждала по следния начин:

$$TL = \delta(TL + CL) + (1 - \delta)LSL$$

(17)

където $0 < \delta < 1$ ако и двата члена трябва ефективно да влязат в крайната функция на загубите.

Един от най-разпространените алгоритми за оптимизация, използвани в машинното самообучение, както и в статистиката, е спускането по градиент, както е показано по-долу:

$$w_i^k = w_i^k - \gamma \frac{\partial TL}{\partial w_i^k}$$

(18)

$$b_i^k = b_i^k - \gamma \frac{\partial TL}{\partial b_i^k}$$

(19)

където γ е коефициентът на обучение, който е основен параметър, който може да окаже значително влияние върху резултата от оптимизацията. $\frac{\partial TL}{\partial w_i^k}$ и $\frac{\partial TL}{\partial b_i^k}$ са градиентите или производните на функцията на загубите по отношение на параметрите на обучаемия модел - теглата и отклоненията. Градиентите се получават чрез метода на обратното разпределение на грешката и прилагане на верижното правило.

DQPR използва типа разпределение Хиперболичен синус – Хиперболичен аркуссинус, въведено от Jones и Pewsey (2009 г.), за да генерира условни разпределения. Това е четирипараметрично разпределение, което може да отчита местоположението, мащаба, изкривяването и теглото на опашката и е обобщение на нормалното разпределение. Причината за избора му е удобната му имплементация в TensorFlow и сходните свойства с наклоненото t-разпределение.

В крайните изходни напълно свързани (dense) слоеве на модела DQPR се използва специфична параметризация, за да се гарантира, че параметрите за дисперсия и теглото на опашките са положителни числа, което е предпоставка за прилагането на Хиперболичен синус – Хиперболичен аркуссинус разпределението. Параметризацията е експоненциалната линейна единица плюс 1, за да се осигури неотрицателност.

$$\begin{cases} x + 1 & x \geq 0 \\ -(e^x - 1) + 1 & x < 0 \end{cases}$$

(20)

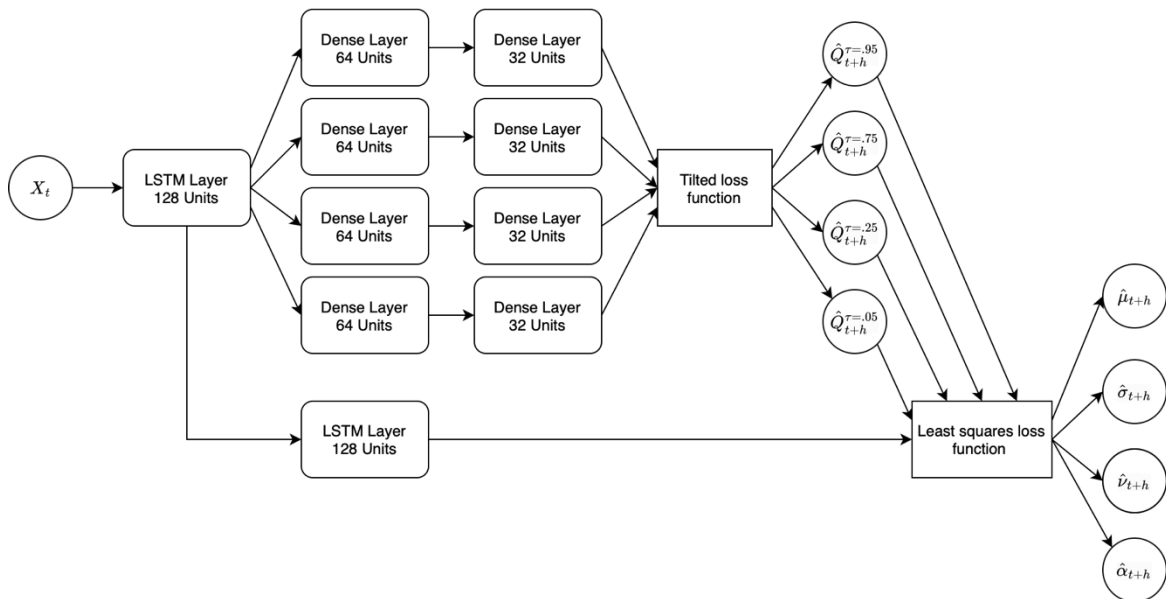
Тази параметризация е необходима и осигурява сходимост на оптимизационните алгоритми, както и възможност за генериране на условно разпределение от семейството на Хиперболичен синус – Хиперболичен аркуссинус.

За да се комбинират две функции на загубите в модела, е приложен вид динамично претегляне. Различни версии на претеглянето бяха тествани и използвани за трите емпирични изследвания. За първия казус за прогнозиране на рецесиите, свързани с пандемията от коронавирус, версията на модела разчиташе на високо тегло (95%) за квантилната целева функция за 90% от епохите на обучение (продължителност на обучението на модела) и ниско тегло (5%) за останалата част от обучението. Съответно теглото за втората функция на най-малките квадрати, която определя параметрите на условното разпределение, се поддържа ниско (5%) през 90% от продължителността на обучението и преминава към висока стойност (95%) за последните 10% от продължителността на обучението.

За двете емпирични изследвания, свързани с прогнозирането на цената на природния газ на Балканския газов хъб и конструирането на ветрилообразни графики на инфлацията в България, моделът използва високо тегло (90%) за квантилната целева функция за 60% от епохите на обучение (продължителност на обучението на модела) и ниско тегло (10%) за останалата част от обучението. Съответно теглото за втората функция на най-малките квадрати, която определя параметрите на условното разпределение, остава ниско (10%) през 60% от продължителността на обучението и преминава към висока стойност (90%) за последните 40% от продължителността на обучението.

Чрез прилагането на тази архитектура и експериментирането с нея за целите на емпиричните изследвания, представени в следващата глава, бяха създадени две разширени версии на архитектурата. Фигура 6 представя промените в сравнение с по-простата версия, представена по-горе, за архитектурата, използвана за първото проучване на случай за прогнозиране на рецесията, свързана с пандемията.

Фигура 6: Разширена версия на DQPR за прогнозиране на рецесията, свързана с пандемия



Източник: Автор

И двете разширени архитектури се основават на оценяването на четири отделни квантила (.05, 0.25, 0.75 и .95 персентила). За тази цел се използва разклоняване на мрежата за оценка на всеки отделен квантил, като всеки клон съдържа два напълно свързани (dense) слоя. В крайна сметка всички условни квантили се оценяват едновременно, като се използва общата целева функция, както е описано по-горе. В тази разширена архитектура се използват два вида активиращи функции - сигмоидната и функция на хиперболичния тангенс. Сигмоидната функция е дефинирана по-долу:

$$\sigma(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} = 1 - \sigma(-x)$$

(21)

В плътните слоеве се използва функцията на хиперболичния тангенс, както е дефинирано по-долу:

$$\tanh x = \frac{\sinh x}{\cosh x} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1}$$

(22)

Тази трансформация променя мащаба на изходните стойности на напълно свързания слой на невронната мрежа така, че той да лежи между 1 и -1. Следователно изходната стойност на напълно свързания слой в горната схема се определя по следния начин:

$$a_i^k = \tanh(a_i^k w_i^k)$$

(23)

където a_i^k е активацията на i -тия неврон от k -тия слой.

Друга особеност на разширената архитектура е използването на рекурентни слоеве. В този случай бяха използвани слоеве с дълга краткосрочна памет (LSTM), след като в различни контексти бяха тествани както обикновени рекурентни единици, така и филтрирани рекурентни единици (GRU). Вижте Hochreiter, Schmidhuber (1997) за LSTM слоевете, Cho et al. (2014) за GRU слоевете и Bengio et al. (1994) за обикновените рекурентни слоеве и свързаните с тях проблеми. Също така, добър преглед на текущото състояние и приложенията на модели на времеви редове, базирани на LSTM слоеве, може да се намери в Hewamalage, Bergmeir, and Bandara (2021).

Тази обобщена архитектура позволява да се използват множество прогнозни променливи и множество минали стойности за всяка променлива. От друга страна, тя позволява обучението на модела за прогнозиране и на няколко времеви стъпки напред, което я прави гъвкава по отношение на използването. Моделът DQPR е реализиран с помощта на библиотеката TensorFlow, а за обучението на модела е използван оптимизаторът ADAM (Kingma and Ba, 2014). Библиотеката TensorFlow използва автоматично диференциално смятане и спускане по градиент във времето за рекурентни невронни мрежи (Rumelhart, Hinton, Williams, 1986; Williams and Zipser, 1992).

Както вече беше обсъдено, епистемичната несигурност се определя като ограничение в знанията на наблюдателя или прогнозиращия по отношение на интересувания го процес на генериране на данни. Основно допускане за епистемичната несигурност е, че тя може да бъде намалена чрез натрупване на допълнителни знания или данни. В по-практически план това може да включва натрупване на повече наблюдения, намиране на нови прогнозни променливи или тестване на по-добри модели.

Според предложената класификация на несигурността епистемичната несигурност може да бъде разделена на два други подтипа несигурност: несигурност свързана с модела, която е свързана с избора на семейство модели и избора на архитектурата на модела, и несигурност свързана с приближението, която е свързана с несигурността на свързана с избраните хиперпараметри на модела и неопределеността свързана с избраната извадка от данни.

На практика несигурността свързана с приближението може да се оцени количествено чрез оценка на несигурността на параметрите на модела и е лесно да се изследва избраното пространство от хипотези чрез техника за търсене. Тъй като обаче базовата истина е неизвестна, единственият начин за количествено определяне на несигурността на модела е чрез тестване на различни

семейства модели и архитектури. В контекста на една изкуствена невронна мрежа може да се каже, че по-значителната промяна на архитектурата на практика означава предлагане на ново семейство модели, поради което някои оптимизации на хиперпараметри в този контекст могат да се разглеждат като промяна на пространството на хипотезите.

В контекста на вероятностното прогнозиране с изкуствени невронни мрежи основната тема, която представлява интерес, са методите за количествена оценка на несигурността на параметрите в невронните мрежи. Краткият преглед на съответната литература разглежда няколко метода, популярни в литературата за дълбоко обучение.

Отпадането или dropout (Srivastava et al. 2014), е техника за регуларизация, при която произволна част от невроните или активациите в даден слой на невронната мрежа се определят като равни на нула, което на практика изключва техния ефект върху крайния резултат. Отпадането се реализира чрез конструиране на маскиращ вектор на отпадане, където всеки елемент се изтегля независимо от разпределение на Бернули с предварително определена пропорция, която след това се умножава с активациите на даден слой. За разлика от отпадането, което обикновено е процес, активиран по време на обучението на модела, отпадането по метода Монте Карло (Gal and Ghahramani, 2016) или MC Dropout е същата концепция, но се прилага по време на извода. По този начин различните активации се деактивират при всяка итерация на извода и моделът става стохастичен. Според Gal и Ghahramani (2016) всеки извод на невронната мрежа генерира наблюдение от Байесовото апостериорно разпределение и чрез генериране на голям брой наблюдения (100 е добра начална точка, предложена от авторите) може да се изчисли приближение до апостериорът. Методът има своите критици, но на практика е много лесен за прилагане и изключително евтин от изчислителна гледна точка. Отпадането може да се прилага за всякакъв тип архитектура и тип слой на невронната мрежа, включително рекурентни слоеве.

Поради лесната му реализация, прозрачност и изчислителна ефективност беше решено да се приложи метода на отпадането по метода Монте Карло за количествено определяне на несигурността свързана с параметрите. Отпадането и разширението му по метода Монте Карло са лесно приложими за употреба в TensorFlow за всеки тип слой и архитектура. Освен това повтарящите се слоеве могат да бъдат обект на повтарящо се отпадане, което е стратегия за регуларизация на повтарящите се слоеве. По този начин невронната мрежа се превръща в байесова или псевдобайесова по следния начин. Моделът се използва за извеждане на прогнозното разпределение, обозначено с:

$$p(y|X, \mathcal{D})$$

където y е целева променлива, X е вектор на регресорите и \mathcal{D} е информационният набор $\mathcal{D} = (y_t, X_t)_{t=1}^T$. Целта е да се научи разпределението на параметрите на модела, известно също като параметрично апостериорно разпределение $p(\Theta|\mathcal{D})$.

Както беше споменато по-рано, отпадането по метода Монте Карло работи чрез случайно задаване на нула на изходните стойности на невроните или на активациите, което регулира невронната мрежа по време на извода. Всяка итерация на извод на невронната мрежа съответства на различно наблюдение от извадка от приблизителното параметрично апостериорно разпределение $q(\Theta|\mathcal{D})$:

$$\Theta_k \sim q(\Theta|\mathcal{D})$$

(24)

където Θ_k представлява т.нар. конфигурация на отпадане или набор от параметри, получени в резултат на еднократен извод k на стохастичната невронна мрежа. Вземане на наблюдение от приблизителното параметрично апостериорно разпределение $q(\Theta|\mathcal{D})$ позволява интегриране по метода Монте Карло на вероятността на модела, което разкрива прогнозното разпределение, както следва:

$$p(y|X) \approx \int_{\Omega} \underbrace{p(y|X, \mathcal{D})}_{\text{likelihood}} \underbrace{q(\Theta|\mathcal{D})}_{\text{p.posterior}} d\Theta$$

(25)

$$p(y|X) \approx \frac{1}{K} \sum_{k=1}^K p(y|X, \Theta_k) \text{ s. t. } \Theta_k \sim q(\Theta|\mathcal{D})$$

(26)


За по-голяма простота често се приема, че вероятността е нормално разпределена, въпреки че досега използвахме четирипараметричното разпределение от семейството на Хиперболичен синус – Хиперболичен аркуссинус:

$$p(y|X, \Theta) = F(\hat{\mu}(X, \Theta), \hat{\sigma}(X, \Theta), \hat{\nu}(X, \Theta), \hat{\alpha}(X, \Theta))$$

(27)

Параметрите се извеждат от симулациите или от K резултата на невронната мрежа. Фигура 7 илюстрира как отпадането по метода Монте Карло дава различен резултат чрез произволно изключване на активациите на невроните (сиви кръгове) и оставяне на други активации включени (черни кръгове) при всяка итерация на извод. Множество итерации с различни конфигурации на отпадане Θ_k дават прогнозното разпределение на средната стойност $p(\hat{\mu}|X, \Theta)$.

Фигура 7: Бейсова мрежа с отпадане по метода Монте Карло



Източник: Автор, Davis et al. (2020)

Два важни аспекта на прилагането на отпадането по метода Монте Карло са използваната пропорция на отпадане и броят на итерациите, използвани по време на извода. За пропорциите на отпадане Gal и Ghahramani (2016) препоръчват те да бъдат между 10 и 50 %. За приложението на метода в дисертацията беше решено да се използва 10%. Авторите съветват, че броят итерации на извод може да бъде между 30 и 100. Беше решено да се използват 100, поради ниските изчислителни разходи за увеличаване на размера на извадката.

Kendall и Gal (2017 г.) предлагат метод за разделяне на алеаторната и епистемичната несигурност за случая на отпадането по метода Монте Карло в своето изследване, фокусирано върху компютърното зрение. Valdenegro-Toro и Mori (2022) разглеждат и обобщават метода за Flipout и ансамбли от невронни мрежи. Да приемем, че бейсовата невронната мрежа извежда прогнозно разпределение $p(y|X)$, което за простота се приема, че е Гаусово. Моделът извежда две величини $\mu_k(X)$ и $\sigma_k^2(X)$, които са съответно средна стойност и дисперсия за всяка итерация на извод от общия брой K итерации. Параметрите на модела се избират от приблизителното апостериорно разпределение на параметрите $\Theta_k \sim q(\Theta|D)$, които дават различни прогнози $\mu_k(X)$ и $\sigma_k^2(X)$ за всеки извод, при еднакви входящи данни.

$$p(y|X) \sim \mathcal{N}(\mu_*(X), \sigma_*^2(X))$$

(28)

$$\mu_*(X) = \frac{1}{K} \sum_{k=1}^K \mu_k(X)$$

(29)

$$\sigma_*^2(X) = \frac{1}{K} \sum_{k=1}^K (\sigma_k^2(X) + \mu_k^2(X)) - \mu_*(X)^2$$

(30)

Последното уравнение представлява общата прогнозна несигурност или дисперсия $\mathbb{V}(y|X)$. Общата прогнозна несигурност може да бъде разделена на два подкомпонента, като се използва законът за общата дисперсия:

$$\sigma_*^2(X) = \frac{1}{K} \sum_{k=1}^K \sigma_k^2(X) + \frac{1}{K} \sum_{k=1}^K \mu_k^2(X) - \mu_*(X)^2$$

(31)

Това може да се формулира по следния начин:

$$\mathbb{V}(y|X) = \underbrace{\mathbb{E}[\mathbb{V}(y|X, \Theta)]}_{\text{Алеаторна Несигурност}} + \underbrace{\mathbb{V}(\mathbb{E}[y|X, \Theta])}_{\text{Епистемична Несигурност}}$$

(32)

Последната деривация гласи, че за всички итерации на извод с различни конфигурации на отпадане или параметри Θ , средната стойност на дисперсиите представлява алеаторната несигурност, докато дисперсията на средните стойности съответства на епистемичната несигурност.

Третата глава на дисертацията е посветена на три различни приложения на модела DQPR. В тези емпирични изследвания е наложително да се тества и установи стойността на предложената рамка в реални случаи на употреба. За тази цел ефективността на DQPR се измерва с помощта на подходящи показатели и след това се сравнява с референтни модел с различна сложност - от най-прости до по-софистицирани. За всеки конкретен казус се използва различен набор от референтни модели, който да обслужва целите на всяко от емпиричните изследвания.

Първите два съответни показателя, използвани в емпиричните изследвания, са широко използвани мерки за точността на прогнозите. И двата се фокусират върху централните характеристики на прогнозното разпределение. Корен на средната квадратична грешка (RMSE) измерва точността на средната стойност на прогнозното разпределение, а средната абсолютна грешка (MAE) оценява точността на медианата. Непрекъснатата ранжирана вероятностна оценка (CRPS), която е обобщение на средната абсолютна грешка в контекста на вероятностните прогнози, е мярка както за острота, така и за калибрация (Gneiting et al., 2007) и тук

се разглежда като основен показател за точност, който представлява интерес във всички емпирични изследвания. Корен на средната квадратична грешка (RMSE), средната абсолютна грешка (MAE) и непрекъснатата ранжирана вероятностна оценка (CRPS) се използват и в трите емпирични изследвания.

В емпиричните изследвания са използвани пет отделни референтни модела. Първият от тях е AR(1) модел с постоянна дисперсия, използващ първата минала стойност на целевата променлива и свободен член. Постоянната дисперсия се изчислява, като се използват остатъците от тренировъчната извадка. Този модел се използва и в трите емпирични изследвания, тъй като е най-простият начин за изготвяне на вероятностна прогноза, макар и с постоянна дисперсия.

Вторият референтен модел е модел GARCH(1,1) със модел за средната величина AR(1), като отново се използва само първата минала стойност на целевата променлива. Този модел се използва само във второто емпирично изследване за прогнозиране на цените на природния газ на Газовия Хъб Балкан.

Третият референтен модел е вероятностна регресия, базирана на LSTM невронна мрежа, приложен с помощта на рамката TensorFlow. Моделът е приложен с допускането за нормално разпределение, което позволява моделиране на условна средна стойност и условна дисперсия. Този модел също е използван само във второто емпирично изследване за прогнозиране на цените на природния газ на Газовия Хъб Балкан.

Четвъртият референтен модел (линейна несимултанна оценка на квантилите) използва оригиналната процедура на Adrian et al. (2019), описана по-рано в тази глава. Тя включва оценяване на квантилна регресия отделно за всеки квантил, който представлява интерес. В този случай това са четири квантила - .05, .25, .75, .95. Всеки квантил се оценява с помощта на линеен модел. След като се генерират условните квантили, към оценките се прилага наклоненото t-разпределение, за да се генерира окончателната прогнозна плътност. Този модел се използва в конкретния случай на прогнозиране на рецесиите, свързани с пандемията, за да се сравнят резултатите от различните подобрения на тази първоначална процедура.

Петият референтен модел (линейна симултанна оценка на квантилите) е подобрена версия на оригиналната процедура на Adrian et al. (2019), която има две основни разлики. Първата е, че четирите квантила се оценяват едновременно, както е предложено от Rodrigues and Pereira (2020). Втората е допълнителен член във целевата функция, който решава проблема с пресичането на квантилите, по предложение на Bondell et al. (2010). Този критерий се използва в конкретния случай на прогнозиране на рецесиите, свързани с пандемията, за да се проследят подобренията между несимултантната оценка на квантилите и DQPR.

Накрая, за да се извърши анализ на чувствителността на модела DQPR и да се изведе относителната важност на променливите, се използва методът на локалните интерпретируеми обяснения на модела (или накратко LIME), предложен от Ribeiro et al. (2016). Този метод научава интерпретируем линеен

модел около всяка прогноза (или извод), който може да осигури локална обяснимост. Глобалната обяснимост се получава, като се използва локалната обяснимост върху дадена извадка от прогнози и се изчисляват средните абсолютни приноси към прогнозите за всяка независима променлива.

Глава 3: Приложения на дълбоката квантилна вероятностна регресия

Прогнозиране в реално време на рецесията свързана с пандемията през 2020 г. в малки отворени икономики

Според An et al. (2018) рецесиите не са рядко явление. Авторите анализират данни за 153 епизода на рецесии в 63 държави в периода 1992-2014 г. и установяват, че държавите са в рецесия средно през 12% от времето. Въпреки това събитията, свързани с рецесия, точния момент на настъпване и размера, остават трудни за прогнозиране както за експертите, така и за статистическите модели (Lewis and Pain, 2014). От друга страна, по-значими събития като голямата рецесия, настъпила между 2007 и 2009 г., и неотдавнашната рецесия, причинена от политиките на локдаун в отговор на пандемията от коронавирус, са още по-голямо предизвикателство за прогностичите и вземащите решения, тъй като представляват реализация на рискове с ниска вероятност (Makridakis et al., 2009; Chen, 2019; Antipova, 2020). Докато голямата рецесия беше причинена от натрупване на системен риск, който в ретроспекция се оказа видим във финансовите индикатори (Altunbaz et al., 2017), политиките на локдаун по линия на пандемия от коронавирус бяха приложени в отговор на необичаен и неочакван шок. Ето защо тази последна криза може да се счита за едно от най-големите предизвикателства за професията на прогностика през последните десетилетия.

В отговор на подобни предизвикателства Международният валутен фонд (МВФ), наред с други институции, използва рамка за количествена оценка на макроикономическите рискове за растежа, която стана известна като "растеж под риск" (Prasad et al., 2019). Тъй като моделите, предназначени за прогнозиране на централна характеристика на разпределението на определен индикатор, като средната стойност или медианата, не са в състояние да обхванат асиметрията между рискове в посока нагоре и надолу, се налага оценка на несигурността около точковите прогнози (Clemens, 2004). Един от начините за справяне с тази необходимост, който напоследък се подкрепя от все повече изследвания и е в основата на рамката на МВФ за растеж под риск, е да се моделира емпирично бъдещото разпределение на растежа въз основа на текущите макроикономически и макрофинансови условия. Макар че за постигането на тази задача са използвани различни модели, сред които бейсови VAR модели (Carriero, 2020), модели на стохастичната волатилност (Iseringhausen, 2021) и GARCH модели (Brownlees, Souza, 2021), в настоящата статия се акцентира върху методи, основани на квантилна регресия.

В една влиятелно изследване Adrian et al. (2019) използват двустъпкова процедура за конструиране на условни квантили с помощта на квантилен регресионен модел и впоследствие приспособяват вероятностно разпределение към оценените квантили. Авторите изследват условното разпределение на растежа в САЩ с акцент върху финансовите условия. Те установиха няколко стилизирани факта относно условното разпределение на растежа за САЩ, сред които силна отрицателна корелация между условната средна стойност и дисперсията и значителна връзка между настоящите финансови условия и бъдещите измествания в долната опашка на условното разпределение. Същото заключение е потвърдено от De Santis и Van der Veken (2020 г.), които извършват подобно изследване, включващо данни от началото на 2020 г. и отделен набор от данни, обхващащ периода на пандемията от испански грип в редица държави. Figueres and Jarociński (2020), потвърждават същите стилизирани факти, установени от Adrian et al. (2019) за еврозоната.

В конкретния случай се прилага нов подход, вдъхновен от полупараметричната двустъпкова процедура, използвана от Adrian et al. (2019) и De Santis and Van der Veken (2020). Предложеният подход се състои от едностъпков модел, който се основава на изкуствени невронни мрежи и извежда параметрите на прогнозното разпределение на растежа. Моделът в същността си зависи от оценката на условни квантили и за тази цел е базиран на две отделни целеви функции, които са динамично претеглени. Предложените тук подобрения са в четири отделни области:

1. Едновременно генериране на квантили, както е предложено от Rodrigues и Pereira (2020), за да се облекчи проблемът с пресичането на квантили;
2. Въвеждането на загуба от пресичане на квантилите към целевата функция, която допълнително решава проблемът с пресичането на квантилите, както е предложено от Bondell et al. (2010);
3. Използване на архитектура на изкуствени невронни мрежи, базирана на слоеве с дълга краткосрочна памет (LSTM) (Hochreiter, Schmidhuber, 1997), за моделиране на нелинейни връзки между регресорите и целевата променлива и по-добро отразяване на рецесията, свързана с пандемията, в сравнение с линеен модел;
4. Комбиниране на двете стъпки от процедурата в един модел, който се оптимизира чрез минимизиране на две целеви функции едновременно – квантилна функция, използвана за оценка на условните квантили, и функция по метода на най-малките квадрати за оценка на крайните параметри на прогнозното разпределение.

Тази комбинация от подобрения за целите на настоящото проучване се нарича модел на дълбок растеж под риск или по-технически – дълбока квантилна вероятностна регресия (накратко DQPR). Първоначално фокусът на изследването беше върху макроикономическото развитие на България, но след като бяха получени предварителни резултати, беше решено предложеният подход да бъде

изпробван върху три други малки отворени европейски икономики, сравнително сходни по отношение на размера и структурата на икономиката. Поради това предложената процедура беше тествана върху данни за България, Естония, Литва и Румъния, обхващащи периода на локдаун по линия на пандемията от коронавирус и свързаната с нея рецесия, и постигна по-добри резултати извън извадката в четири от тях в сравнение с три референтни модела.

Проучването е структурирано, както следва. В следващия раздел са разгледани данните, използвани в това проучване, а в третия раздел са обобщени емпиричните резултати. Последният раздел съдържа обсъждане на резултатите и заключенията от проучването.

За този анализ целевата променлива, която представлява интерес, е тримесечният темп на растеж на сезонно и календарно изгладените верижно свързани обеми на БВП. Към момента на изготвяне на настоящия текст се използва наличното окончателно издание на данните за БВП. Освен минали стойности на целевата променлива беше съставен списък с водещи показатели за финансовите условия и икономическата активност, които да бъдат използвани като независими променливи. Изборът на водещи показатели беше направен по подход, подобен на Adrian et al. (2019), De Santis and Van der Veken (2020), Figueres and Jarociński (2020) и Prasad et al. (2019). Беше наложително те да са налични за по-дълъг период от време и първоначалният избор за начална година на извадките беше 2000 г., тъй като това гарантираше достатъчно дълга тренировъчна извадка и възможност да се задели тестова извадка. Понастоящем съществуват много интересни водещи индикатори, които могат да се използват за подобни задачи за макроикономическо прогнозиране, но основният им недостатък е липсата на натрупани исторически данни. Освен това беше решено да се включат само показатели, които са налични (публикувани) за определено тримесечие до края на същото тримесечие, за да може да се използват текущите стойности на прогнозните показатели във времето спрямо стойностите на растежа на БВП, които се публикуват по-късно. Поради това краткосрочните показатели, които се публикуват със значително закъснение, не бяха включени в набора от данни за моделиране, въпреки тяхната значимост, тъй като те имат ограничено приложение при прогнозиране в реално време на растежа на БВП.

Всички променливи са нормализирани със средна стойност 0 и стандартно отклонение 1 преди да бъдат използвани в модела. Общата извадка обхваща периода от 2000Q1 до 2021Q4 и е разделена на обучителна и тестова извадка. Първите 64 тримесечия бяха използвани за обучение на модела (от 2000Q1 до 2016Q2), а последните 22 тримесечия - за валидиране на точността на модела (от 2016Q3 до 2021Q4). За конструиране на тренировъчната и тестовата извадка е използван подходът на променливия прозорец. Окончателните спецификации са представени по стилизиран начин в Таблица 1.

Таблица 1: Окончателни спецификации на модела

Държава	Спецификации
България	$GDP_t = f(GDP_{t-1}, SENTIMENT_t, SOFIX_t, US\ BOND\ YIELD_t)$
Естония	$GDP_t = f(GDP_{t-1}, SENTIMENT_t, OMXTGI_t)$
Литва	$GDP_t = f(GDP_{t-1}, SENTIMENT_t, LT\ BOND\ YIELD_t)$
Румъния	$GDP_t = f(GDP_{t-1}, SENTIMENT_t, US\ BOND\ YIELD_t)$

Източник: Автор

В изброените спецификации лявата страна описва целевата променлива, а дясната - набора от регресори. За България и Естония включването на националните индекси на фондовите борси води до оптимални резултати. В случая на България включването на доходността на 10-годишните ДЦК на САЩ носи допълнителна прогностична стойност. По подобен начин за Литва използването на доходността на 10-годишните литовски ДЦК води до най-добро представяне на модела. За Румъния използването на доходността на американските 10-годишни държавни облигации води до по-добри резултати в сравнение с използването на национални показатели.

Моделът DQPR беше тестван спрямо три отделни референтни модела. Първият от тях е модел от тип AR1, който използва условната средна стойност, генерирана от модела, и постоянна условна дисперсия, изчислена върху тренировъчната извадка, като параметри на нормалното разпределение. Другите два модела се основават на оригиналния двустъпков подход. И двата референтни модела използват линейна квантилна регресия, но първият ги оценява несимултантно, докато за втория условните квантили се оценява симултантно и се прилага използването на загубата от пресичане, подобно на модела DQPR. За генерирането на условното разпределение на тези два модела се използва наклоненото t-разпределение. Точността на моделите се оценява извън-извадково върху тестовата извадка, обхващаща рецесията на пандемичния локдаун, настъпила през 2020Q1 и/или 2020Q2. Основните показатели, които са използвани за измерване и сравняване на ефективността, са корен на средните квадратичните грешки (RMSE) и средните абсолютни грешки (MAE) за точковата точност на прогнозите и непрекъснатата ранжирана вероятностна оценка (CRPS) като основен показател за качеството на прогнозните разпределения. За DQPR медианната прогноза се използва както при изчисляването на RMSE, така и на MAE.

Моделът DQPR постига по-висока точност в сравнение с референтния модел както през периода на отрицателен растеж, през който всяка държава преминава между първото и второто тримесечие на 2020 г, така през цялата тестова извадка. Моделът също така разпознава надеждно рисковете от спад, като се има предвид увеличената дисперсия на разпределението през периодите на отрицателен растеж. Референтните модели не успяват да разпознаят както времето на низходящия растеж, така и рисковете от него за всички държави. Изглежда обаче, че той се представя задоволително през периодите на подем. Всички модели се

представят слабо, що се отнася до прогнозиране на възстановяването след първоначалния спад и за разпознаване на рискове в посока нагоре. Всички модели се представят добре по време на периодите без рецесия, но моделът DQPR е по-добър при моделирането на рецесията, причинена от неочаквания шок на глобалното налагане на локдаун по линия на пандемията. Чрез използването на голям брой LSTM единици моделът DQPR успява да разпознае силно нелинейна връзка между регресорите и икономическия растеж. По време на част от първоначалните експерименти беше забелязано, че намаляването на броя на LSTM единиците намалява точността му по време на периодите на рецесия и прави представянето му по-близко до референтните модели. По-подробни резултати за производителността могат да се видят в Таблица 2.

Таблица 2: Оценка на ефективността

Държава	Модел	RMSE	MAE	CRPS
България	AR1	2.3857	1.2188	1.2146
	Линейна несимултанна оценка на квантилите	2.0498	1.7895	1.6312
	Линейна симултанна оценка на квантилите	2.6840	1.3597	1.7928
	DQPR	1.4828	0.8782	1.0693
Естония	AR1	1.9221	1.1094	1.1026
	Линейна несимултанна оценка на квантилите	1.6027	1.0163	1.3550
	Линейна симултанна оценка на квантилите	2.3538	1.5348	1.6579
	DQPR	1.3445	0.8066	1.0182
Литва	AR1	2.2336	1.0367	1.0311
	Линейна несимултанна оценка на квантилите	1.5220	0.7641	0.9111
	Линейна симултанна оценка на квантилите	2.0726	0.9709	0.9086
	DQPR	1.1068	0.5047	0.7649
Румъния	AR1	2.9932	1.4178	1.4122
	Линейна несимултанна оценка на квантилите	1.8490	1.1164	1.3224
	Линейна симултанна оценка на квантилите	2.6532	1.3937	1.6711
	DQPR	1.7456	1.0263	1.0648

Източник: Автор

DQPR води по отношение на RMSE, MAE и CRPS във всички държави. Референтният модел за несимултанна квантилна оценка постига по-добри резултати в сравнение с другите два референтни модела. Моделът обаче страда значително от проблема с пресичането на квантилите, който леко се облекчава, който бива прикрит при финалната оценка на прогнозното разпределение. DQPR превъзхожда най-добрия референтен модел в показателите за точност, с между 5,6% и 33,9%. Обобщението

на процентното подобрене по държава и по индикатор може да бъде намерено в таблицата по-долу.

Таблица 3: Подобрене в точността на DQPR спрямо най-добрия референтен модел

	RMSE	MAE	CRPS
Bulgaria	27.7%	27.9%	12.0%
Estonia	16.1%	20.6%	7.7%
Lithuania	27.3%	33.9%	15.8%
Romania	5.6%	8.1%	19.5%

Източник: Автор

Моделът DQPR генерира условни разпределения за всички държави, които потвърждават някои от констатациите на Adrian et al. (2019). Наблюдават се както симетрични условни разпределения по време на експанзия, така и негативен наклон на разпределението по време на периоди на рецесия. Освен това се наблюдава и негативна корелация между средната стойност и дисперсията на разпределението на растежа. Тези резултати бяха потвърдени за четирите държави от извадката, както за тренировъчната извадка, така и за тестовата извадка.

За да се извърши анализ на чувствителността и да се извлече важноста на променливите от всеки модел, средният абсолютен пределен принос на всяка променлива към резултата от модела е изчислен с помощта на метода LIME за тестовата извадка, както и за 2020Q2, когато рецесията е била наблюдавана във всички държави. Резултатите от анализа са представени по отношение на относителната важност в Таблица 3.

Таблица 3: Относителна важност на променливите

Държава/индикатор	Тестова проба	2020Q2
България		
БВП	71.28%	54.28%
Индикатор за икономическите нагласи	18.55%	38.01%
SOFIX	5.25%	3.24%
Доходност по ДЦК на САЩ	4.92%	4.46%
Естония		
БВП	68.19%	75.30%

Индикатор за икономическите нагласи	20.87%	24.43%
ОМХТGI	10.94%	0.26%
Литва		
БВП	46.06%	4.08%
Доходност по ДЦК на Литва	31.20%	17.02%
Индикатор за икономическите нагласи	22.74%	78.90%
Румъния		
Доходност по ДЦК на САЩ	36.79%	23.33%
БВП	36.18%	10.44%
Индикатор за икономическите нагласи	27.03%	66.23%

Източник: Автор

Забелязва се, че за всички страни, с изключение на Румъния, БВП има най-висока средна важност за тестовата извадка. За Румъния доходността по американските облигации е средно най-важната променлива. За България и Естония индикаторът за нагласите е втората по важност променлива, за Литва - доходността по литовските ДЦК, а за Румъния - БВП. Когато се разглежда второто тримесечие на 2020 г., се наблюдава значително нарастване на значението на индикатора за икономическите нагласи във всички държави, а за Литва и Румъния той има най-високо относително значение за дадения период. Това показва факта, че индикаторът за нагласите има по-голяма роля за точното прогнозиране на икономическите рецесии в сравнение с индикаторите за финансов стрес, което е изненадващ резултат.

Пандемията от COVID-19 и рецесията, която много страни преживяха поради въведените политики на локдаун, представляваха безпрецедентно предизвикателство за вземащите решения и прогнозиците. Както частните предприятия, така и държавните институции трябваше бързо да се адаптират към това сътресение и да прилагат политики за справяне с последиците, в контекста на ограничена предвидимост. Макар че е практически невъзможно да се предвиди предварително подобно събитие като пандемията от коронавирус и нейните последици, може да се прогнозира нейното въздействие върху икономиката чрез водещи показатели, което би могло да подпомогне процеса на вземане на решения.

Настоящото проучване показва, че един опростен модел, използващ специфични за страните показатели за икономическите нагласи, както и специфични за страните и глобални финансови променливи, може успешно да прогнозира рецесии, причинени от неочаквани шокове като пандемията от коронавирус. Сравнителното представяне на модела на изкуствената невронна мрежа DQPR

доказва, че той е полезен инструмент за моделиране на макроикономическите рискове, свързани с локдауна по линия на пандемията от коронавирус през 2020 г. в четири малки отворени икономики в Европа. Способността му да моделира силно нелинейни връзки го прави по-добър от набор от линейни референтни модели в този случай.

За България и Литва моделът DQPR успява да предвиди много точно отрицателния ръст на БВП през второто тримесечие на 2020 г., когато се усещат най-силните икономически последици от локдауна. В случая с Естония моделът DQPR не предвижда точно началото на рецесията през първото тримесечие на 2020 г., но успява да предвиди много точно отрицателния растеж през второто тримесечие на 2020 г. Не е ясно обаче дали динамиката на растежа през първото тримесечие не е резултат от сезонно изглаждане. За Румъния моделът DQPR не успява да предвиди размера на рецесията през 2020Q2, но все пак превъзхожда значително линейните референтни модели по отношение на MAE и CRPS. Освен недостатъка си, изразяващ се в много по-ниска точност на прогнозите по отношение на прогнозирането на пандемичната криза, линейните референтни модели постигат задоволителни резултати при прогнозиране на растежа през периодите на растеж. DQPR превъзхожда в индикаторите за точност най-добрия референтен модел с до 33.9%.

Недостатък, който се споделя както от предложения модел DQPR, така и от линейните референтни модели, е ограничената им способност да прогнозираат подем след първоначалния спад на икономическия растеж. Този резултат се наблюдава във всички държави и на пръв поглед проблемът е в т.нар. форма на рецесията през 2020 г., която във всички държави, представляващи интерес, изглежда има V-образна форма. Моделите са обучени на рецесиите, причинени от световната финансова криза, които за разглежданите държави са имали U-образна или W-образна форма, което може би е причината моделите да не успяват да предвидят бързо и силно възстановяване след само едно или две тримесечия на спад на БВП. Включването на индикатори за отложено потребление може да е начин да се отчете силното възстановяване, тъй като рецесията не беше резултат от спад в доходите, а невъзможността за потребление поради политиките на локдаун.

По отношение на използваните показатели в четирите държави в извадката, е очевидно, че както специфичните за всяка държава, така и глобалните фактори на финансов стрес имат прогностична стойност по отношение на икономическия растеж и конкретно в задачата за прогнозиране на пандемичната рецесия. За България и Естония беше показано, че използването на близки стойности на националните индекси на фондовите борси води до оптимални резултати. В случая на България включването на доходността на 10-годишните ДЦК на САЩ носи допълнителна прогностична стойност. За Литва включването на доходността на 10-годишните литовски държавни облигации доведе до най-добре представящата се спецификация на модела. За Румъния доходността по 10-

годишните ДЦК на САЩ има по-голяма прогностична сила по отношение на прогнозирането на пандемичната рецесия в сравнение със специфичните за страната финансови показатели. Освен това и в четирите държави е доказано, че един опростен модел, съдържащ малко показатели, дава оптимални резултати.

С помощта на подхода LIME беше оценена относителната важност на независимите променливи за модела DQPR в четирите държави. Когато се разглежда цялата тестова извадка, БВП има най-висока средна важност за цялата тестова извадка, с изключение на Румъния. За Румъния доходността по щатските ДЦК е средно най-важната променлива. Конкретно за 2020 г. се наблюдава значително нарастване на значението на индикаторите за икономическите нагласите във всички държави, като за Литва и Румъния той има най-високо относително значение за дадения период. Този резултат показва важността на използването на специфичния за страната индикатор за икономическите нагласите при прогнозиране на свързаната с пандемията рецесия.

Моделът DQPR съчетава няколко неотдавнашни подобрения, предложени от автори, работещи върху квантилни регресионни модели, което му позволява да смекчи известни проблеми като пресичане на квантилите. Първото подобрение е симултантното оценяване на квантилите, което позволява да се генерират произволен брой квантили в рамките на една процедура за оценяване и с помощта на една целева функция. Това ускорява процеса на генериране на условните квантили, но също така е показано, че облекчава проблема с пресичането. Второто подобрение е изричното включване на член за загуба от пресичане във целевата функция, което допълнително смекчава проблема. Освен това комбинирането на двата етапа на оригиналната процедура в един модел създава една вътрешно съгласувана процедура, без да се жертва нейната гъвкавост. Работата в контекста на изкуствена невронна мрежа позволява да се конструира модел с две функции на загубите и да се комбинират двете стъпки на оригиналната процедура за оценяване в процедура с една стъпка.

Освен това настоящият анализ потвърждава наличието на отрицателна корелация между условната средна стойност и дисперсията на разпределението на растежа, както и на симетрични условни разпределения по време на експанзия и негативен наклон на разпределението по време на периоди на рецесия за четирите икономики, анализирани в настоящото изследване, в съответствие със стилизираните факти, които Adrian et al. (2019 г.) установяват за САЩ, а Figueres и Jarociński (2020 г.) потвърждават и за еврозоната.

Вероятно прогнозиране на цените на природния газ на Газовия Хъб Балкан използвайки дълбоко самообучение

Природният газ е една от основните енергийни суровини от световно значение. Употребите му включват отопление, производство на електроенергия, гориво за транспорта, както и като суровина за производството на пластмаси, торове и текстил. Европа разчита на природния газ в значителна степен. По данни на

Евростат делът на природния газ в общия енергиен микс на ЕС през 2020 г. е бил 23.7%, а природният газ е представлявал 31.7 % от крайното енергийно потребление на домакинствата през същата година. По отношение на доставките, голяма част от природния газ в ЕС се внася, като зависимостта от вноса е 83.6% за 2020 г., според публичната база данни на Евростат. Въпреки че ЕС е предприел значителни стъпки за диверсифициране на доставките, все още внася от Русия около 40% от общото си потребление на природен газ през 2021 г., по данни на Европейската комисия.²

През последните две десетилетия ценообразуването на природния газ в Европа претърпя значителни промени. Преди 2000 г. цените на природния газ в ЕС се определяха почти изцяло от дългосрочни договори, индексирани с цената на суровия петрол. Цените на природния газ следваха тенденциите в цените на суровия петрол, което осигуряваше донякъде стабилна референтна цена. Тази система обаче не отразяваше динамиката на търсенето и предлагането и участниците на пазара в ЕС не можеха да се възползват от периодите на по-евтино предлагане. През последното десетилетие цените на природния газ в ЕС постепенно се отдалечиха от индексирването спрямо петрола и се насочиха към конкурентен модел наречен „gas-on-gas“, при която цените отразяват множество продавачи и купувачи на природен газ на спот пазарите. Zhang et al. (2018) твърдят, че механизмът на ценообразуване на база хъб е свързан с по-малко екстремни колебания, тъй като не е толкова уязвим към спекулации. Борсата за прехвърляне на титули (TTF) в Нидерландия се разви като най-ликвидния хъб и подходящ ценови бенчмарк в ЕС. В крайна сметка подобни хъбове бяха създадени и в други държави, като Газовия Хъб Балкан в България, който стартира в началото на 2020 г. Поради значителната степен на пазарна интеграция на европейските газови пазари (Broadstock et al., 2020) цените следват сходни тенденции в различните газови хъбове (Berrisch and Ziel, 2022).

По отношение на динамиката на цените пазарът на природен газ в миналото е бил нестабилен поради дисбаланса между търсенето и предлагането, скъпата инфраструктура, нивата на съхранение, метеорологичните условия, промените в политиките и политическите събития (Siddiqui, 2019). Оказа се, че зависимостта от един-единствен голям доставчик като Русия също носи значителен риск (Weisser, 2007 г.). В исторически план е имало прекъсвания на доставките (през 2006 г. и 2009 г.), но с началото на руската инвазия в Украйна през февруари 2022 г. поредица от политически решения на руското правителство и промени по изпълнението на договорите от страна на руския доставчик "Газпром" доведоха до безпрецедентни епизоди на нестабилност и скокове на цените, свързани най-вече с ограничените и несигурни доставки. На фона на по-студеното време, опасенията относно пускането на "Северен поток 2" и нарастващото напрежение

² Европейска комисия: https://commission.europa.eu/news/focus-reducing-eus-dependence-imported-fossil-fuels-2022-04-20_en

между Русия и Украйна, доставките на газ по линията Ямал намаляха в началото на февруари 2022 г., което доведе до първия от поредицата безпрецедентни скокове на цените на европейските газови пазари (Европейска комисия, 2022 г.). След началото на руското нахлуване в Украйна на 24 февруари 2022 г. ЕС наложи тежки санкции на Русия, а "Газпром" поиска плащания в рубли по дългосрочните си договори, което доведе до още един временен, но значителен скок на цените. В крайна сметка поредица от прекъсвания на доставките за различни държави в Европа доведоха до подобни скокове и нестабилност на пазарите на природен газ (Европейска комисия, 2022 г.).

Настоящата енергийна криза в Европа води до безпрецедентни нива на несигурност, при които краткосрочното планиране е едновременно важно и трудно. В контекста на европейските свободни пазари способността да се правят точни прогнози за цената на природния газ е важна за различните участници на пазара и определя решенията им за количествата и сроковете на покупките на спот пазарите. Според Siddiqui (2019 г.) все по-честото използване на фючърси като инструмент за хеджиране срещу рискове, обусловени от цените, се дължи на невъзможността на пазарните участници да прогнозира точно спот цените. Множество скорошни проучвания са разглеждали въпроса за прогнозиране на цените на природния газ (Siddiqui, 2019; Su et al. 2019a, Su et al. 2019b; Jianliang et al., 2020), но те са били фокусирани върху точковото прогнозиране. Съществуват само няколко проучвания, които се фокусират върху въпроса за прогнозиране на цената на природния газ в контекста на вероятностното прогнозиране (Berrish and Ziel, 2021; Ding et al., 2022). Вероятностните прогнози носят информация за цялото прогнозирано разпределение, а не само за централната стойност, и в този смисъл те са оценка на бъдещите рискове. В контекста на цената на природния газ в Европа, където се наблюдават периоди на по-висока волатилност, вероятностните прогнози биха били по-информативни и по-подходящи в сравнение с точковите прогнози, особено когато се наблюдава хетероскедастичност и са възможни промени във вероятностното разпределение на наблюдавания процес на генериране на данни.


Настоящото изследване е насочено към вероятностно прогнозиране на цените на природния газ в рамките на деня на Газовия Хъб Балкан (на кратко - BGN) с цел моделиране и прогнозиране на риска и предлага използването на дълбок квантилен вероятностен регресионен модел за постигане на тази цел. Тази архитектура на невронната мрежа е използвана преди това за прогнозиране на икономическата криза, причинена от политиките на локдаун в отговор на пандемията в няколко държави в Източна Европа (Янчев, 2022 г.), и е адаптирана към текущата задача за прогнозиране. В изследването е използвана историческа извадка от дневни цени, започваща от стартирането на BGN през 2020 г. до декември 2022 г. Използвани са допълнителни обяснителни променливи като 1-месечните фючърси на TTF, спотовите цени на суровия петрол URALS, цените на европейските квоти за емисии (EUA), както и данни за обема на вноса от Газпром

през няколко тръбопровода. Предложената ефективност на модела извън извадката е тествана спрямо два статистически референтни модела и един нов метод от сферата на дълбокото самообучение. Предложеният модел постига най-добро представяне извънизвадково по отношение на няколко показателя в сравнение с референтните модели.

Проучването е структурирано, както следва. В следващия раздел са разгледани данните, използвани в това проучване, а в третия раздел са обобщени емпиричните резултати. Последният раздел съдържа обсъждане на резултатите и заключенията от проучването.

В проучването целевият индикатор на фокус, е дневната процентна промяна на цената на природния газ на Газовия Хъб Балкан в рамките на деня. Разглежданият период е между началото на 2020 г., когато за първи път е пуснат в експлоатация Газовият Хъб Балкан, и декември 2022 г. От Фигура 8 може да се види как цените на газовия хъб се развиват във времето както по отношение на нивото, така и по отношение на процентното изменение. Относително периодът до края на 2020 г. се характеризира с ниска волатилност и едва забележима тенденция. След началото на 2021 г. се наблюдава а забележимо нарастване на волатилността, а в края на 2021 г. се наблюдава рязко преминаване към определена възходяща тенденция и струпвания на по-голяма волатилност. От септември до декември 2022 г. фактори като високите нива на съхранение на газ в ЕС и новозавършената инфраструктура в няколко държави, включително България, водят до постепенно понижаване на цените.

Фигура 8: Динамика на цената на Газовия Хъб Балкан в рамките на деня по нива и процентни изменения



Източник: Автор, Газов Хъб Балкан

Освен първия лаг на целевата променлива, бяха избрани няколко водещи индикатора поради потенциалната им прогностична стойност при прогнозиране на целевата променлива. Водещите показатели бяха подбрани по подход, подобен на Berrish and Ziel (2021) и Ding et al. (2022). Списък на избраните водещи показатели може да бъде намерен в Таблица 4.

Таблица 4: Избрани водещи показатели

Индикатор	Описание и източник
Обем на вноса на руски природен газ по тръбопроводи в ЕС	Ежедневна честота, Източник: Платформа за прозрачност на ENTSOG
1-месечни фючърси на TTF	Ежедневна честота, Източник: Investing.com
Годишни фючърси на европейски квоти за емисии	Ежедневна честота, Източник: Investing.com
Спот цени на суровия петрол URALS	Ежедневна честота, Източник: Investing.com

Източник: Автор

Всички използвани показатели са преобразувани в дневни процентни изменения. За всички променливи са използвани първите минали стойности спрямо целевата променлива. Всички променливи са нормализирани със средна стойност 0 и стандартно отклонение 1 преди да бъдат използвани в модела. Общата извадка обхваща периода от 07.01.2020 г. до 30.12.2022 г. и е разделена на тренировъчна и тестова извадка. Първите 668 дни са използвани за самото обучение на модела, а последните 75 тримесечия са използвани за апробиране на модела на данни тестовата извадка. За конструирането на тренировъчната и тестовата извадка е използван подходът на променливия прозорец. През първите месеци от стартирането на Газовия Хъб Балкан имаше множество дни без сделки, за които не бяха реализирани цени в рамките на деня. За да се отстранят липсващите стойности, беше извършена импутация, при която всяка липсваща стойност беше заменена с последната налична стойност.

Сравнението на точността на избраните модели се оценява чрез псевдоизвадка от извадката. Тестовата извадка обхваща периода между 18.03.2022 г. и 30.12.2022 г., който се характеризира с клъстери на волатилност и значителни скокове в цената на природния газ. Използвани са няколко показателя за измерване и сравняване на точността на моделите, както по отношение на точкова точност на прогнозата, така и по отношение на качеството на вероятностните прогнози. Таблица 5 представя RMSE, MAE и CRPS за всички модели.

Таблица 5: Оценка на ефективността извън извадката

Модел	RMSE	MAE	CRPS
AR(1) с постоянна дисперсия	0.1177	0.0787	0.0621
AR(1) - GARCH(1,1)	0.1180	0.0785	0.0605
Вероятностна регресия, базирана на LSTM	0.1091	0.0734	0.0570
Дълбока квантилна вероятностна регресия (DQPR)	0.1079	0.0712	0.0566

Източник: Автор

DQPR води по всички показатели за точност, а вероятностната регресия, базирана на LSTM, е на второ място отново по всички показатели. По отношение на CRPS двата модела се представят почти идентично и следователно и двата модела са подходящи за разглежданата задача. Референтният модел AR(1) с постоянна дисперсия превъзхожда референтния модел AR(1)-GARCH(1,1) по отношение на всички показатели, а последният има най-лошо общо представяне. Подобрието в точността, в резултат от употребата на DQPR спрямо най-добрия референтен модел е между 0.7% за CRPS и 3.0% за MAE.

Таблица 3: Подобриение в точността на DQPR спрямо най-добрия референтен модел

	RMSE	MAE	CRPS
Подобриение в %	1.1%	3.0%	0.7%

Източник: Автор

За да се извърши анализ на чувствителността и да се извлече относителната важност на променливите от DQPR модела, средният абсолютен педелен принос на всяка променлива към резултатите от модела е изчислен по метода LIME за цялата тестова извадка. Резултатите за обяснимостта са представени по отношение на относителната важност в Таблица 6.

Таблица 6: Относителна важност на променливите

Индикатор	Важност на променливата
1-месечни фючърси на TTF	60.07%
BGH Цена на природния газ в рамките на деня	19.84%
Европейски квоти за емисии	14.32%
Цена на суровия петрол URALS	3.42%
Обем на вноса на руски природен газ по тръбопроводи в ЕС	2.35%

Източник: Автор

Едномесечните фючърси на TTF имат най-голяма важност в тестовата извадка, следвани от цената в рамките на деня на BGN и европейските квоти за емисии. Цената на суровия петрол URALS и вносът от Русия по тръбопроводи имат много по-ограничена важност. Тези резултати доказват, че използването на данни от водещия европейски хъб TTF има висока добавена стойност за прогнозиране на цените на природния газ на регионален хъб като BGN.

През 2022 г. Европа се изправи пред сериозно предизвикателство с разгръщането на военен конфликт на нейна територия. По отношение на икономическото въздействие най-големият ефект се усети на енергийните пазари и по-конкретно на пазара на природен газ. След първите месеци на инвазията в Украйна последваха поредица от политически решения на руското правителство и промени по изпълнението на договори от страна на руския доставчик "Газпром". Ефектът от тези действия и цялостната ескалация на конфликта доведоха до безпрецедентни ценови скокове и волатилност на европейския пазар на природен газ. Към момента на написване на тази статия пазарите са достигнали състояние на относително спокойствие, но едва след поредица от събития, случили се през третото тримесечие на 2022 г., като намаляването или прекратяването на доставките на Газпром за повече европейски държави (включително Франция и Латвия) и експлозиите на газопроводите "Северен поток 1" и "Северен поток 2", които им нанесоха непоправими щети.

Повишеният риск на газовия пазар засегна всички участници на пазара - както предприятията, така и правителствата. Настоящото проучване се опитва да предложи решение за работа на пазар с повишен риск чрез вероятно прогнозиране на цените на газа в рамките на деня на Газовия Хъб Балкан за един ден напред. В изследването се предлага подход за генериране на вероятностни прогнози, като се използва архитектура на невронна мрежа, наречена дълбока квантилна вероятностна регресия (DQPR). Методът включва оценка на четири условни квантила и последваща оценка на параметрите на разпределението от типа Хиперболичен синус - Хиперболичен Аркусинус, което е четирипараметрично разпределение, което може да отчита местоположение, дисперсия, наклон и тегло на опашките и е обобщение на нормалното разпределение. Предложеният подход е сравнен с два статистически референтни модела и още един нов подход от сферата на дълбокото самообучение. Двата статистически референтни модела са модел AR(1) с постоянна дисперсия, оценен върху тренировъчната извадка, и модел AR(1)-GARCH(1,1), който моделира както условната средна стойност, така и дисперсията. И за двата модела е направено допускане за нормалност и симетрия. Подходът за дълбоко обучение представлява вероятностна регресия, базирана на LSTM, която позволява директна оценка на параметрите на нормално разпределение.

Няколко водещи индикатора бяха използвани с предложения модел DQPR и вероятностната регресия, базирана на LSTM. Тези индикатори включват 1-месечните фючърси на TTF, обемите на вноса на руски газ по тръбопроводи в ЕС,

спот цената на URALS и едногодишните фючърси на европейските квоти за емисии. Сравнението на резултатите показва, че предложеният модел DQPR превъзхожда останалите референтни модели по отношение на RMSE, MAE и CRPS и постига подобрене в точността с до 3.0% спрямо референтния модел базиран на LSTM. Тези резултати утвърждават модела DQPR като надежден метод за прогнозиране на цените на природния газ.

Ако разгледаме относителната важност на променливите за DQPR модела, най-важният показател е 1-месечният фючърс на TTF, следван от цените в рамките на деня на BGN и европейските квоти за емисии. Тези резултати доказват, че използването на данни от водещия европейски хъб TTF има висока добавена стойност за прогнозиране на цените на природния газ на регионален хъб като BGN.

Настоящото проучване има няколко нови приноса. Това е първото изследване, което се фокусира върху прогнозирането на цените на природния газ на Газовия Хъб Балкан. В него се използва нова и полезна стратегия за прогнозиране на цените на един от многобройните газови хъбове в Европа, като се използва водещата газова борса TTF като прогностичен фактор. Проучването преработва новия модел DQPR от първоначалното му приложение за моделиране на рискове от рецесия към задачата за генериране на вероятностни прогнози на цените на природния газ.

Бъдещата работа по темата може да се съсредоточи върху разширение на спецификацията на модела с допълнителни индикатори на търсене и предлагане, по-дългосрочно прогнозиране, прилагане на данни от други газови хъбове от световно значение и експериментиране с по-широк набор от алгоритми за машинно самообучение.

Разширени приложения: Измерване на алеаторната и епистемичната несигурност при прогнозиране на потребителската инфлация в България

През последното столетие прогнозирането на инфлацията представлява голям интерес за икономистите както от теоретична, така и от практическа гледна точка. Инфлацията е един от много важните и може би фундаментални маркери за състоянието на икономиката, а теориите за връзката ѝ с безработицата, наречени обобщено крива на Филип, исторически са представлявали голям интерес за теоретичните икономисти (за обобщение виж Fuhrer et al., 2009 или Kasabov et al., 2017). От друга страна, измерването и прогнозирането на инфлацията има основно значение за определянето на паричната политика и инфлационното таргетиране, с което са ангажирани централни банки като ЕЦБ и Федералния резерв на САЩ. Инфлацията има много аспекти като потребителски цени, цени на производител, заплати, вносни и износни цени, цени на жилищата и инфлационни очаквания, които са важни за процеса на вземане на решения от фирмите, потребителите и правителствата.

След световната финансова криза от 2008 г. и 2009 г. и последвалата я рецесия, която се разпространи в Европа и по-голямата част от света, инфлацията в Европа

остана ниска, а в някои страни дори отрицателна. По данни на НСИ и Евростат България също преживя продължителен период на отрицателна годишна инфлация, измерена чрез хармонизирания индекс на потребителските цени (ХИПЦ), между август 2013 г. и декември 2016 г. Според ЕЦБ (Ciccarelli and Osbat, 2017) факторите, обуславящи ниската инфлация в Европа след 2012 г., включват както вътрешни, така и външни фактори за различните държави, но също така установяват ясни закономерности в отделните страни. Ниските или намаляващи външни цени на суровините вероятно са били основният фактор за ниската или отрицателната инфлация. От друга страна, след рецесията от 2009-2010 г. Европа премина през криза свързана с държавния дълг, която засегна някои от южните членове на ЕС като Испания, Италия и Гърция и което се отрази на съвкупното търсене в тези държави, но и на целия ЕС. Следователно потиснатото съвкупно търсене след Голямата рецесия доведе до този дълъг период на ниска или дори отрицателна инфлация за някои от държавите - членки на ЕС.

За разлика от това, през периода 2020-2023 г. инфлацията в целия свят рязко нарасна поради няколко фактора. Пандемията причинена от коронавируса SARS-COV-2 предизвика безпрецедентни смущения в световната икономика както по отношение на предлагането, така и на търсенето. Причината за това бяха политиките на локдаун, въведени едновременно в много държави, които предизвикаха остри регионални рецесии, но и нарушиха драматично глобалните вериги на предлагане (Barlow et al., 2022). Това прекъсване беше толкова силно, че доведе до глобални дисбаланси, които все още не са преодолени, като например глобалния недостиг на полупроводници (Attinasi et al., 2021), недостига и повишаването на цените на металите и хранителните продукти³, както и недостига на корабни контейнери (Toygur et al., 2022).

В допълнение към глобалните смущения, причинени от пандемията от коронавирус, през февруари 2022 г. руската инвазия в Украйна създаде предпоставки за безпрецедентна криза на европейските енергийни пазари и повишаване на световните цени на храните. В началото на военния конфликт Русия и държавната компания "Газпром" постепенно преустановиха износа на природен газ за множество европейски държави в отговор на мащабните финансови и търговски санкции, наложени от ЕС и САЩ. Тези действия засегнаха пряко пазарите на природен газ, електроенергия и суров петрол в Европа и имаха странични ефекти в целия свят (Adolfson et al., 2022). Освен това войната в Украйна застраши глобалната продоволствена сигурност, тъй като двете страни в конфликта са два от най-големите световни производители на пшеница (Nasir et al., 2022). Предсказуемо тези събития се изразиха в много голямо увеличение както на цените на производител, така и на потребителските цени през 2022 г. в Европа и света. (изречение за увеличението на цените на производител и потребителските цени в проценти). В тази нестабилна среда задачата за

³ Въз основа на индексите на цените на храните и металите, събирани от МВФ.

прогнозиране на инфлацията става все по-трудна, но и все по-необходима за всички икономически агенти.

По-рано беше обсъдено, че вероятностните прогнози са по-ценни от точковите прогнози, особено когато става въпрос за извънредна волатилност или асиметрия на рисковете. Много централни банки в миналото са възприели публикуването на ветрилообразни графики, които представят несигурността около прогнозите за инфлацията или растежа. Централни банки като ФЕД, ЕЦБ, Българската народна банка и много други редовно публикуват ветрилообразни графики на инфлацията и растежа. Ветрилообразната графика обикновено се представя като централна прогноза и множество доверителни интервали, подобни на интервалите на прогнозиране, около тази централна прогноза. Колкото по-далеч от централната прогноза са тези интервали, толкова по-малка е вероятността за реализация на подобен сценарий. Характерно за тези графики е, че те се разширяват или разрастват с увеличаване на прогнозния хоризонт, което се дължи на увеличаването на несигурността при нестационарните процеси. С други думи, колкото по-далеч в бъдещето се опитва да се прогнозира, толкова по-голяма е несигурността около прогнозата.

Целта на това проучване е да демонстрира подход за конструиране на ветрилообразната графика на инфлацията, като се използва бейсова версия на модела DQPR, която отчита както алеаторната, така и епистемичната несигурност. Това включва количествено определяне както на несигурността, присъща на процеса на генериране на данни или на тяхното измерване (алеаторна), така и на несигурността, свързана с параметрите на модела и избора на модела и неговите асимптотични свойства (епистемична). Това се постига с помощта на приближение на бейсовите методи в контекста на изкуствените невронни мрежи, като се използва техниката на отпадане по метода Монте Карло (MC dropout). Структурата на изследването е следната: в следващия раздел е представено подробно описание на използваните данни, а последните два раздела представляват обобщение на резултатите и дискусия, в която са изложени заключенията.

За събирането на данните за тази задача бяха използвани различни източници. Общият хармонизиран индекс на потребителските цени за България, изтеглен от Евростат, е използван като целева променлива за това упражнение. Месечните данни за безработицата въз основа на коригирани редове от Наблюдението на работната сила също са изтеглени от Евростат. Данните за външните цени на суровините са взети от портала за данни на МВФ. Следните цени на суровините са избрани за включване като обяснителни променливи:

- Индекс на цените на храните (2016=100), включително зърнени храни, растителни масла, месо, морски дарове, захар и други храни
- Индексът на всички метали (2016=100) включва алуминий, кобалт, мед, желязна руда, олово, молибден, никел, калай, уран и цинк.

- Индекс на цените на суровия петрол (2016=100), проста средна стойност на три спот цени - Брент, Западен Тексас и Дубай Фатех
- Цена на природния газ за ден напред на TTF в щатски долари

Бяха разгледани и два допълнителни ендогенни фактора, които са силно свързани с инфлацията: отклонение от потенциалния растеж и инфлационните очаквания. Отклонението от потенциалния растеж се изчислява като отклонение от потенциалното производство, а потенциалното производство се изчислява с помощта на HP филтър (Giorno et al., 1995). Инфлационните очаквания са представени от закъснелите стойности на целевата променлива за инфлацията, както и от индикатора за потребителските нагласи за възприемане на инфлацията. Използваният показател за потребителските нагласи е възприемането на инфлацията от потребителите през следващите 12 месеца.

Общият избор на обяснителните променливи е вдъхновен от изследването на кривата на Филипс в България на Kasabov et al. (2017). Авторите изтъкват, че освен фактори като производствената разлика и инфлационните очаквания важни детерминанти на инфлацията са и външните шокове от страна на предлагането като международните цени на петрола, цените на други вносни стоки и ефективният валутен курс. Нещо повече, през последния период след 2020 г., през който в България се наблюдава устойчиво ускоряване на инфлацията, са налице ясни и силни шокове от страна на предлагането по отношение на цените на енергията, храните и металите.

Бяха тествани различни комбинации от изброените по-горе показатели, като най-добре се представи спецификацията, съдържаща първите минали стойности на безработицата, ХИПЦ, индекса на цените на металите и индекса на цените на храните.

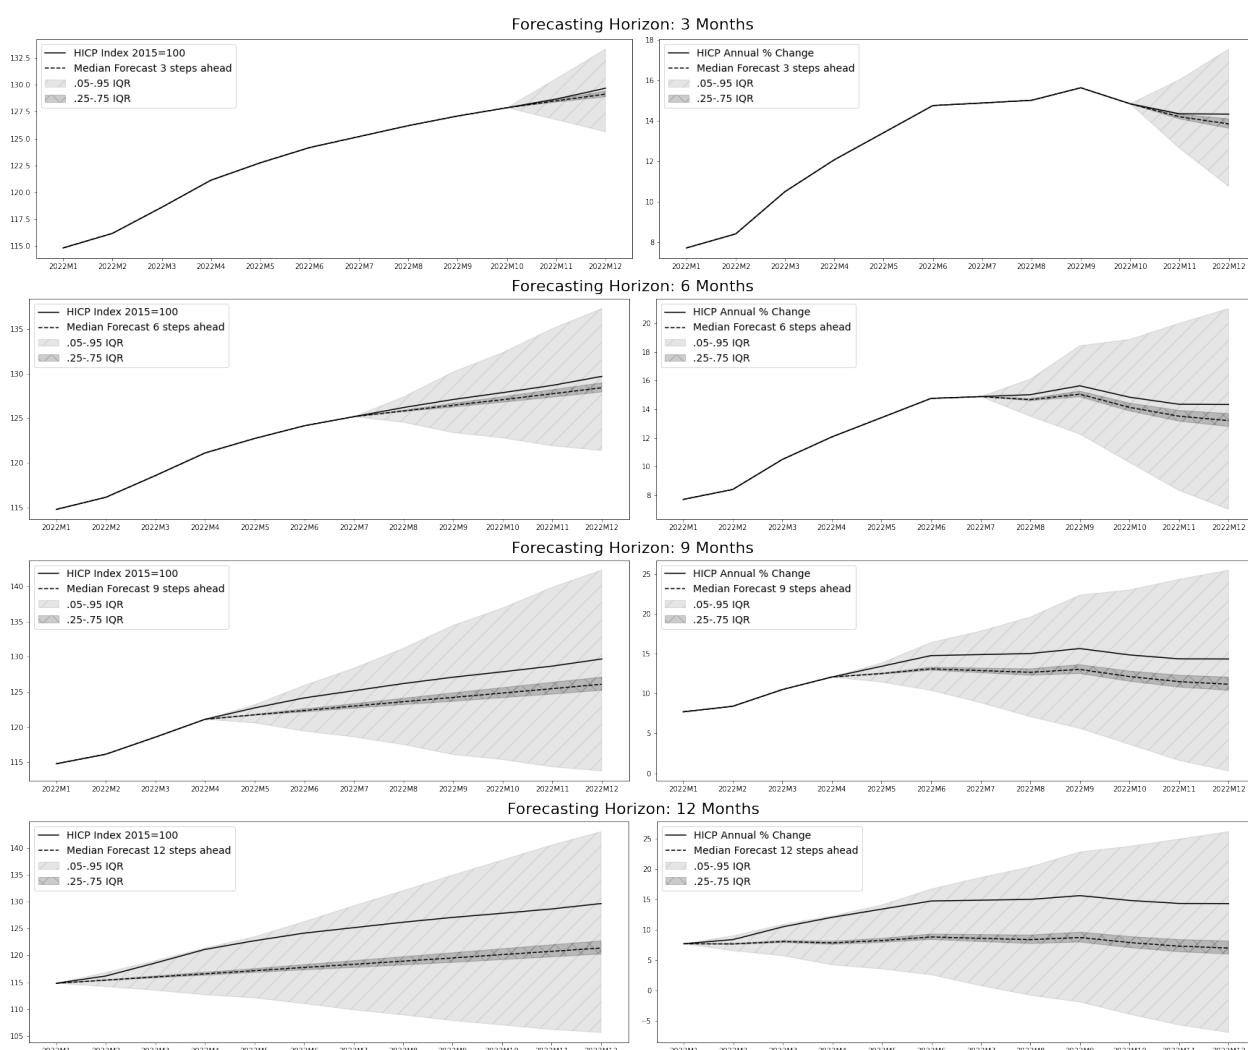
В рамките на това изследване бяха извършени две отделни процедури. Първата включваше прогнозиране за 1 месец напред върху тестовата извадка за целите на декомпозиция на несигурността. Втората беше насочена към прогнозиране с няколко различни прогнозни хоризонта за целите на конструирането на ветрилообразните графики на инфлацията. При втората процедура действителните стойности на обяснителните променливи бяха използвани като допускания при генерирането на прогнозите. В предишните глави тази част от набора от данни беше обозначена с X_{T-h} - обяснителните променливи, налични след време T . И за двете процедури за прогнозиране са генерирани 100 извадки от параметрите на прогнозните разпределения. Освен това са генерирани ветрилообразните графики и за линейния референтен модел AR1, като е използвано допускане за нормално разпределение, и са сравнени с резултатите от предложения модел DQPR по няколко показателя за точност.

Резултатите от прогнозирането за 1 месец напред върху тестовата извадка показват декомпозиция на общата дисперсия на прогнозите на техните алеаторни и епистемични компоненти и сравняват различните спецификации на модела по

отношение на размера на общата дисперсия, относителния размер на епистемичната несигурност и точността на модела на тестовата извадка. На първо място, епистемичната несигурност е значително по-малка в сравнение с алеаторната по отношение на размер във всички спецификации. По-малката обща дисперсия, както и по-малкият относителен размер на епистемичната дисперсия, са свързани с по-добро представяне на модела извън извадката, въпреки че тази връзка не е еднозначна. Основанието за това би било, че по-малката обща дисперсия е свързана с прогнози с по-висока острота, докато, колкото по-слабо дефинирана е спецификацията на модела, толкова по-големи са общата и епистемичната дисперсия. Вижда се обаче, че има и изключения, като например спецификацията, съдържаща минали стойности на ХИПЦ, индекса на цените на храните и потребителските нагласи по отношение на инфлацията, която е по-добра по отношение на резултатите на тестовата извадка в сравнение с тази, съдържаща минали стойности на ХИПЦ и индекса на цените на храните, въпреки по-голямата обща дисперсия и по-големия относителен размер на епистемичната дисперсия. Подобен анализ може да бъде доразвит за сравняване на конкуриращи се модели.

Втората процедура включва генериране на вероятностните прогнози, използвани за конструиране на ветрилообразните графики. Използвани са четири различни хоризонта на прогнозиране - 3 месеца, 6 месеца, 9 месеца и 12 месеца. Прогнозите са генерирани като месечно процентно изменение и след това са преобразувани в индекс на ХИПЦ в ниво и годишно процентно изменение. Моделът DQPR извежда 100 извадки от параметрите на разпределението за всяка времева стъпка, а окончателните параметри на разпределението, използвани за създаването на диаграмите на ветрилата, са средните стойности на параметрите в извадките.

Фигура 9: Ветрилообразни графики на инфлацията



Източник: Автор

Графиките на вентилаторите, представени в Фигура 9 има три основни компонента - централната прогноза, която се основава на медианата, интерквантилния интервал (IQR) от .25 до .75 перцентил и интерквантилния интервал от .05 до .95 перцентил. Двата междуквантилни диапазона отделят две отделни области с по-ниска и по-висока несигурност. От диаграмите се вижда, че интервала от .25 до .75 перцентил е много по-тесен, което показва, че прогнозните разпределения са с по-голяма куртоза. Освен това всички графики сочат към наклон, който в някои случаи е значителен. В повечето графики изкривяването е ясно положително, с по-голяма площ, покрита от двата интерквантилни интервала и особено интервала .05 - .95. Това показва силни рискове за повишаване на инфлацията въз основа на обяснителните променливи. Действителните стойности на инфлацията във всички случаи попадат извън интервала .25 - .75 и въпреки силните възходящи рискове за инфлацията медианната прогноза подценява инфлацията за всеки прогнозен хоризонт. Това подценяване е по-силно изразено с увеличаване на прогнозния хоризонт.

Както за индекса, така и за годишното процентно изменение се наблюдава разширяване на ветрилообразната диаграма с увеличаване на прогнозния хоризонт, което съответства на нарастващата несигурност. Това е очаквано, тъй като както индексът, така и годишното процентно изменение не са стационарни динамични редове. Това е свойство на вероятностните прогнози, което се очаква почти задължително. Въпреки това, както бе споменато по-рано, това свойство на вероятностните прогнози зависи в голяма степен от характеристиките на въпросните динамични редове.

Таблица 7: Резултати от прогнозирането

Модел	Хоризонт на прогнозиране	RMSE	MAE	CRPS
AR1	3 месеца	0.0036	0.0025	0.0020
	6 месеца	0.0043	0.0031	0.0023
	9 месеца	0.0048	0.0039	0.0028
	12 месеца	0.0050	0.0043	0.0029
DQPR	3 месеца	0.0033	0.0025	0.0020
	6 месеца	0.0038	0.0029	0.0023
	9 месеца	0.0033	0.0027	0.0021
	12 месеца	0.0039	0.0032	0.0025

Източник: Автор

Таблица 7 съдържа по-подробни резултати от оценката на точността. Няколко показателя за ефективност се наблюдават през всички прогнозни хоризонти за DQPR и еталона AR1. Те включват RMSE, MAE и CRPS. Относително високата точност на прогнозите през всички хоризонти може да се дължи на използването на действителните стойности на обяснителните променливи като допускания при конструирането на прогнозите за плътността. AR1 и DQPR имат идентични резултати за MAE и CRPS за 3-месечния хоризонт и CRPS за 6-месечния хоризонт, но с увеличаване на прогнозния хоризонт предимството на DQPR е по-изразено. Подобриенето в точността, което постига DQPR спрямо референтния модел е между нула и 31.3%, разглеждайки различните прогнозни хоризонти. Таблицата по-долу представя обобщение на подобриенето за всеки индикатор на точността и всеки хоризонт на прогнозиране.

Таблица 3: Подобрене в точността на DQPR спрямо референтния AR1 модел

	Хоризонт на прогнозиране	RMSE	MAE	CRPS
Подобрение в %	3 месеца	8.3%	0.0%	0.0%
	6 месеца	11.6%	6.5%	0.0%
	9 месеца	31.3%	30.8%	25.0%
	12 месеца	22.0%	25.6%	13.8%

Източник: Автор

За да се извърши анализ на чувствителността и да се извлече важноста на променливите от DQPR модела, средният абсолютен пределен принос на всяка променлива към резултатите от модела е изчислен по метода LIME за цялата тестова извадка. Резултатите за обяснимостта са представени по отношение на относителната важност в Таблица 8.

Таблица 8: Относителна важност на променливите

Индикатор	Важност на променливата
Безработица	38.40%
Индекс на цените на металите	28.76%
Индекс на цените на храните	23.68%
ХИПЦ	9.16%

Източник: Автор

Резултатите показват, че безработицата има най-голяма относителна важност, но индексите на външните цени на храните и металите имат общо над 52% от относителната важност. Миналата стойност на ХИПЦ е с най-ниска относителна важност. Това показва, че моделът се движи в значителна степен от външни фактори, но основният фактор безработица е също толкова решаващ за високата точност на DQPR.

Периодът след началото на пандемията от коронавирус се характеризира с висока инфлация в Европа и по света. Първите последици бяха усетени, когато свързаните с пандемията политики на локдаун предизвикаха затруднения в доставките на много стоки. В крайна сметка с отшумяването на рецесиите свързани с пандемията търсенето бързо се възстанови, но предлагането не успя да се приспособи по съответния начин. Важен пример за това беше световният недостиг на полупроводници, който засегна множество големи отрасли като компютърната, автомобилната и битовата промишленост. В последствие руското инвазия в Украйна стана причина за безпрецедентна енергийна криза в Европа, която се

отрази на цените на енергията в световен мащаб. Енергийната инфлация имаше силен ефект и върху други сектори на икономиката (Yagi and Managi, 2023) и подхранваше потребителските очаквания за висока и устойчива инфлация (Kilian and Zhou, 2022).

В настоящето изследване е разгледана темата за прогнозиране на инфлацията в условията на висока инфлация. Ветрилообразните графики са утвърден инструмент за оповестяване на прогнозите за инфлацията и свързаната с тях несигурност, използван редовно от централните банки по света. Поради това беше решено да се приложи предложената дълбока квантилна вероятностна регресия (DQPR), в задачата за конструиране на подобни графики, която може да отчита както наклона, така и куртозата на прогнозното разпределение. Цялостната архитектура на модела е почти идентична с тази, използвана за прогнозиране на цените на природния газ на Газовия Хъб Балкан. Той е разширен с помощта на техниката на отпадане по метода Монте Карло (Monte Carlo Dropout), за да се даде възможност за оценка на несигурността на параметрите, която е подкомпонент на епистемичната несигурност.

Фокусът на това упражнение беше моделирането и прогнозирането на инфлацията на потребителските цени в България, измерена чрез ХИПЦ. За тази цел беше събрани месечни данни, обхващащи периода между 2000 и 2022 г., като бяха включени както ендогенни, така и екзогенни фактори по отношение на българската икономика. Окончателният набор от показатели, използвани в модела, бяха безработицата, индексът на цените на храните, индексът на цените на металите и лагът на ХИПЦ.

При използване на 80 % от общата извадка моделът DQPR беше самообучен и оценен в тестовата извадка върху останалите 20 %. Бяха генерирани прогнози с четири различни хоризонта на прогнозиране - 3 месеца, 6 месеца, 9 месеца и 12 месеца. Получените ветрилообразни графики, построени с тези прогнози, показват силен положителен наклон, което говори за силни рискове в посока нагоре за инфлацията през наблюдавания период. От друга страна, централната медианна прогноза подценява действителната инфлация през периода, обхванат от тестовата извадка. Резултатите от DQPR бяха сравнени с референтен AR1 модел и макар че двата модела имат почти идентични резултати в 3-месечния хоризонт, с нарастването на прогнозния хоризонт предимството на DQPR е по-значително и моделът постига подобрене в точността спрямо референтния модел с до 31.3%.

Освен това при създаването на диаграмите на ветрилата несигурността беше количествено определена и разделена на алеаторна и епистемична, като се използваха прогнозите за 1 стъпка напред върху тестовата извадка. На базата на тази процедура общата дисперсия беше декомпозирана на алеаторни и епистемични компоненти и бяха сравнени различни спецификации на моделите по отношение на общата дисперсия на прогнозите, относителния размер на епистемичната дисперсия и точността върху тестовата извадка. Въпреки че по-

малката обща дисперсия и по-малката относителна епистемична дисперсия са свързани с по-добра точност, връзката не е еднозначна. Въпреки това подобен анализ може да бъде доразвит за целите на сравняването на конкуриращи се модели.

Накрая беше изчислена относителната значимост на променливите за DQPR и резултатите сочат, че моделът се влияе в голяма степен от външни фактори като цените на храните и металите. Въпреки това безработицата има най-висока относителна важност, което подкрепя теоретичните основи на кривата на Филип.

Настоящата глава демонстрира, че техники за дълбоко самообучение като DQPR могат да се използват за прогнозиране на инфлацията и за съобщаване на прогнозите под формата на ветрилообразни графики. Освен това този подход позволява по-задълбочен анализ на несигурността, състоящ се от количествена оценка и разграничаване на алеаторната и епистемичната несигурност. Бъдещите усилия биха могли да се съсредоточат върху по-задълбочена количествена оценка на епистемичната несигурност и оценка и по-специфично на несигурността свързана с избора на модел.

IV. Научни и приложни приноси

Приносите на дисертацията могат да бъдат разделени на три основни категории - научни приноси, научно-приложни приноси и методологически приноси. Основните области на приносите са икономика, иконометрия и машинно самообучение.

Сред научните приноси са:

- Предложен е нов метод за подобряване на икономическите прогнози, който използва архитектура на невронна мрежа за вероятно прогнозиране на времеви редове, наречена дълбока квантилна вероятностна регресия (DQPR).

Сред научно-приложните приноси са:

- Предложеният модел DQPR превъзхожда набор от референтни модели, когато се прилага за прогнозиране на свързаните с пандемията рецесии в четири източноевропейски държави, което е оригинален принос в икономическата литература както по отношение на обхвата, така и по линия на резултатите.
- Предложеният модел DQPR надминава както статистически референтни модели, така и такива основани на дълбоко самообучение, когато се прилага за прогнозиране на цените на природния газ на Газовия Хъб Балкан в период на изключителна волатилност, което е оригинален принос в икономическата литература както по отношение на обхвата, така и по отношение на резултатите.

Сред методологическите приноси са:

- Разработена е бейсова версия на модела DQPR, която е приложена при конструирането на ветрилообразни графики на инфлацията в България, както и при количествената оценка и декомпозиция на алеаторната и епистемичната несигурност.
- Алгоритъмът LIME за интерпретируемо машинно самообучение е приложен към модела DQPR, за да се извърши анализ на чувствителността и да се придобие представа за глобалната и локалната обяснимост на модела.

Гореспоменатите приноси водят до нови резултати в областта на икономиката и машинното самообучение и до ясна методология за практически приложения.

V. Съответни публикации

Части от дисертацията са публикувани като самостоятелни изследвания в два журнала. Планира се да бъдат подготвени поне още две публикации по темата на дисертацията.

1. Mihail Yanchev, 2023. "Uncertainty - Definition and Classification for the Task of Economic Forecasting," Bulgarian Economic Papers bep-2023-03, Faculty of Economics and Business Administration, Sofia University St Kliment Ohridski - Bulgaria // Center for Economic Theories and Policies at Sofia University St Kliment Ohridski, revised Mar 2023.
2. Mihail Yanchev, 2022. "Deep Growth-at-Risk Model: Nowcasting the 2020 Pandemic Lockdown Recession in Small Open Economies," Economic Studies journal, Bulgarian Academy of Sciences - Economic Research Institute, issue 7, pages 20-41.

Представените публикации отговарят на изискванията на чл. 12 от Закона за развитие на академичния състав в Република България (ЗРАСРБ), чл. 35 от Правилника за прилагане на ЗРАСРБ (ППЗРАСРБ) и изпълняват националните наукометрични изисквания по чл. 1а, ал. 1 от ППЗРАСРБ за Област 3: Социални, стопански и правни науки, Професионално направление 3.8 Икономика.

VI. Заключение

Изследването, представено в тази дисертация, се основава на концепции и иновации от областта на икономиката, иконометрията, статистиката и машинното самообучение. Основната му цел е да обогати познанията за вероятностното прогнозиране в икономиката и да насърчи възприемането използването на вероятностното прогнозиране вместо точковото прогнозиране. Чрез основния си принос дисертацията допълва инструментариума за прогнозиране в икономиката с подход за вероятностното прогнозиране основан на дълбоко самообучение, който е доказал своята надеждност и прозрачност в три предизвикателни емпирични изследвания. Съдейки по емпиричните резултати, новият подход за моделиране на несигурността, предложен в дисертацията, е ценен инструмент за прогнозиране в контекста на редки събития като неотдавнашната пандемия от

коронавирус или войната в Украйна. Общият подход на вероятностното прогнозиране и конкретната методология, представена в дисертацията, биха могли да бъдат ценни за процеса на вземане на решения както в публичния, така и в частния сектор.