

## ТЕХНИКИ ЗА ПРЕДСКАЗВАНЕ НА ВРЕМЕВИ ПОРЕДИЦИ ЧРЕЗ НЕВРОННИ МРЕЖИ

Васил Щерев<sup>1</sup>, Николай Хинов<sup>2</sup>

<sup>1</sup> ТУ - София

<sup>2</sup> ТУ - София

## TECHNICS FOR EXACT TIME SERIES PREDICTION WITH NEURAL NETWORKS

Vasil Shterev<sup>1</sup>, Nikolay Hinov<sup>2</sup>

<sup>1</sup> TU-Sofia

<sup>2</sup> TU-Sofia

### Abstract

*This paper is critical overview about technics for time series prediction with neural networks. Main accent is paper published last year. Many different new approaches have been applied such as long-short term echo state network, deep hybrid neural network, intelligent models and so on. Multi-currency and further forecasting the exchange rates are important aspects in recent days. Also control in anomaly, congestion and bandwidth require precise time series prediction with minimum error. Other interesting topic is multi-step ahead prediction. There are few milestones like algorithms for training process, prediction strategy and criteria for stop training. Prediction of time series is an attempt to predict an evolution of a system through previously observed values. Many real world problems are well defined with related time series and multiple seasonal patterns*

*One dimensional time series prediction is major problem nowadays. These series can describe physical phenomenon, traffic flow, economics dilemma and so on. Focus is on discrete processes nevertheless it is refer to short or long term forecast. New method for process, analysis and segmentation of information are discuss. Also performance of different structure neural network models are examine.*

**Keywords:** neural networks, one dimensional time series, long-short term forecast.

### ВЪВЕДЕНИЕ

От гледна точка на човек, всички физични процеси протичат във времето, като последователността винаги е минало-настояще-бъдеще. Огромна част от въпросните процеси, могат да се опишат с едномерни времеви поредици, които следвайки математичната формалност са непрекъснати и дискретни. От информационна гледна точка непрекъснат сигнал, може да се трансформира в дискретен (с определени загуби). Така много голяма част от заобикалящите ни ежедневни проблеми - потреблението на електричество в дома ни, генерирания информационен трафик, фондовата борса и инвестиционния па-


зар плюс много други - могат да се представят с дискретни едномерни поредици.

Невронните мрежи (НМ) от своя страна са добър инструмент за класифициране, апроксимиране и не на последно място предсказване. Следвайки този ред на мисли настоящият доклад е разделен на следните части: Секция 2 е посветена на краткосрочното предсказване, докато в Секция 3 е разгледадено дългосрочното предсказване и са представени интересни нови похвати за повишаване точността на предсказване. Накрая документа завършва с критичен анализ на разгледаваните методи - техните предимства и недостатъци.

## КРАТКОСРОЧНО ПРЕДСКАЗВАНЕ

Когато става въпрос за предсказване единствено на следващия семпъл във времева поредица, това болшинството авроти считат за краткосрочно изготвяне на прогноза. Възможна е и класификация съгласно пропорцията между дължината на разглеждания "исторически" интервал и бъдещия такъв който искаме да предскажем. Естествено не е изключен и сценарий при който трябва да бъде предсказано поведението на системата напред само по един отчет.

Колкото по-непредсказуемо и хаотично се държи една стохастична система, толкова по-трудно е да се отгатне нейното бъдещо поведение. Авторите в [1] представят дълбока хибридна НМ за предсказване на хаотични времеви серии. Предложеният модел включва всички добре познати стъпки по предобработка на данните, след което те се подават на входа на конволюционна НМ с два слоя плюс един т.нар pooling слой. Понататък следват: connect, GRU, dropout и attention слоеве преди генериране на изходния сигнал, който се подава на т.нар блок за подобрена диференциална еволюция. Последният служи за обратна връзка и донастройване на теглата между отделните слоеве. Илюстрация на концепцията е показана на фиг.1.




Фиг. 1 дълбока хибридна НМ с подобрена диференциална еволюция в топологията на обратната връзка [1]

Данните с които е проверен модела са хаотичната времева серия на Лоренц, общият среден месечен брой слънчеви петна и концентрацията на газ в мини за каменни въглища. Прякото сравнение с други еволюционни алгоритми показва по-ниска средно-квадратична грешка и по-кратко време за достигане на резултата.

Друг хибриден модел за предсказване на мрежови трафик е представен в [2]. Акцента е насочен към 5G трафика на различни мре-

жи, като целта е класификация и/или предсказване независимо от конкретната област на приложение. Предложената рамка е показана на фиг. 2.




Фиг. 2 етапи по предобработка за подобряване на съществуващи модели на времеви серии [2]

Разгледани са сложни сценарий включващи хоризонтален и вертикален хендоф, напускане на един вид мрежа и превключване на друг, както и много други "разклонения". В структурата на deep learning LSTM алгоритъма на входа чрез обработка се взима преценка за значението на всеки семпъл. Изчислява се "нова" памет, след което се преценява дали предходният семпъл трябва да се забрави. На изхода се преценява времето на живот (експозиция) на текущия семпъл с който е запазен моделът. В крайна сметка резултатите от предсказването на трафика са по-добри (в смисъла на MSE) от текущите модели.

Друг краткосрочен модел за предсказване обмяната на множество валути може да се намери в [3]. Приложени са SVR (Support Vector Regressor) и НМ с краткосрочна памет за предсказване на курсовете между най-популярните валути (USD/PKR), като обхваща е до 39 години.


Съгласно авторите в [4] термина "хетеродимензионно-многозадачна невро-еволюция" е използван за предсказване на хаотични времеви серии. Анализа започва с реконструиране на фазовото пространство в което всяка точка представлява едно от възможните състояния на системата. Следват пет мултифакториални оптимизационни алгоритми описващи генерирането на индивиди от родители (със съответните геноми) популация чрез кръстосване, мутация, вертикална трансмисия и т.н. На фиг. 3 е илюстрирана основната идея - теглата между свързаните неврони са отделни гени на родители, които за да генерират следващо поколение т.нар популация (деца) преминават през споменатите по-горе алгоритми.



Фиг. 3 нагледно описание на гени които са тегла между отделни свързани неврони [4].

Базите данни с които е проверена работоспособността са добре известните Лоренц, Maskey-Glass и тази с броя на слънчевите петна. Освен конкурентните резултати, скоростта с която алгоритъма конвергира е по-висока от традиционните еволюционни алгоритми.

Методи за предсказване на времеви серии с множество променливи посредством размити познавателни карти от висок ред и еластични мрежи е изложено в [5], като на фиг. 4 е показан пример за размита познавателна карта с пет възела.




Фиг. 4 пример за размита познавателна карта с пет възела. Ляво - графична структура, дясно - представяне с тегловна матрица [5].

На входа на тази система се подават множество времеви серии от ЕКГ сигнали, които се оптимизират чрез еластични мрежи и на изхода се генерира теглова матрица. Еластичните мрежи от своя страна преминават през процес на декомпозиране-обучение-обратно композиране. Всеки ЕКГ сигнал (във времето) представлява възел в тези еластични мрежи, а различните крос-корелационни величини са теглата между тези възли. Така разработената рамка за предсказване и класифициране на нестационарни времеви поредици базирани на едномерна конволюционна НМ и размити познавателни карти позволява предсказване на шест действия с по-висока точност от досегашните модели.

В [6] е представено влиянието на дължината на паметта на НМ за предсказване на заетостта на спектъра в наземни мобилни ра-

дио-ленти. Този род канали се описват най-често с времечестотната карта, която показва заетостта. Авторите сравняват заетостта на различни по тип канали - постоянно заети (100% от времето); импулсно заети и слабо-заети флукутиращи канали. Подробно е описана работата на LSTM (Long-Short Term Memory) клетките за кратко-дългосточна памет, които са разгледани по-детайлно в следващата секция. Фиг. 5 показва LSTM клетка.



Фиг. 5 LSTM клетка [6].

От така представените три модела за предсказване (НМ със закъснителни елементи, LSTM и сезонна ARIMA Auto-Regressive Integrated Moving Average), е направено сравнение в рамките на 50 часова прогноза. Съдейки по резултатите е очевидно, че паметта на LSTM подобрява точността на предсказването независимо от времевия хоризонт гледан напред. Така колкото по-напред трябва да бъде изготвена прогноза за спектралната заетост (например в IoT среда) LSTM модела дава по-надеждни резултати спрямо "обикновенни" НМ и такива със закъснителна линия на входа.

## ДЪЛГОСРОЧНО ПРЕДСКАЗВАНЕ


Дългосрочната прогноза включва в себе си и краткосрочна такава. Като се добави и ефекта от натрупване на грешката към всеки следващ отчет, може да се разбере интереса на повечето автори към дългосрочното прогнозиране.

Интересен пример за използване на рекурентна НМ за предсказване на температура в IoT приложения контролиращи дома може да се намери в [7]. Обратната връзка на рекурентната НМ за миналия, настоящ и бъдещ отчет е "разгъната", така че да има линейна последователност. LSTM блока е същият както в [6]. Прогнозирана е стойността на относителната влажност и температура в рам-

ките на 24 часа напред, което е важно при умни сгради и системи за мониторинг и отдалечен контрол. Авторите са изследвали и влиянието върху MSE на отделните параметри като брой отчети, епохи, правила за прекратяване на обучението и т.н.


LSTM памет за предсказване на мрежови трафик е използвана и в [8]. Времевите серии са с продължителност от пет минути, час и денонощие. Общото заключение, е че предложеният алгоритъм се справя по-добре в директно сравнение с ARIMA и рекурентни НМ.

Още една гледна точка за предсказване на множество "ходове" напред на система е изложен в [9]. По-специалното тук са множеството изходи на итеративно предсказващия модел с LSTM функционалност. Архитектурата на този модел е илюстрирана на фиг. 6



Фиг. 6 архитектура на модела предложен в [9].


Интересно е да се отбележи, че броя на невроните в скритите слоеве не следва единна последователност на редуциране. Освен това невроните в първите два скрити слоя са както LSTM клетки, така и dropout такива. Невроните между съседните слоеве са напълно свързани. Самият процес по трениране на модела включва освен обичайните етапи по предобработка, нормализация и разделяне на "порции" още избор на размера на най-малките партии за обучение, trial and error процедура, определяне на размера на стъпката за обучение и още много други финни настройки за трениране, които се избират спрямо входната информация. Стратегията за предсказване е показана на фиг.7.



Фиг. 7 схематична диаграма представяща предложената в [9] стратегия за предсказване на множество отчети напред.

Симулационните експерименти са проведени върху бази данни съдържащи реални инженерни измервания (engineering datasets). Според авторите, предложението им е с подобър ефект от моделите предложени до този момент, но производителността, както отбелязват те зависи от характера на времевата серия.

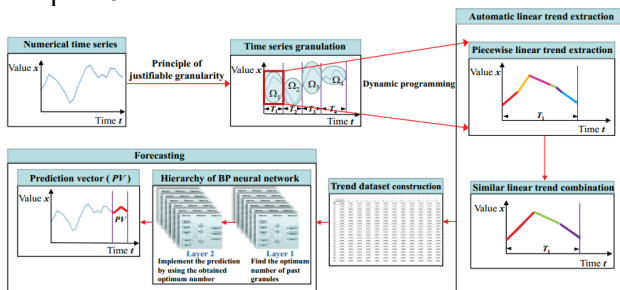
Ехо мрежи за кратко и дългосрочно предсказване са изследвани в [10].



Фиг. 8 обща архитектура на ехо мрежата предложена в [10].

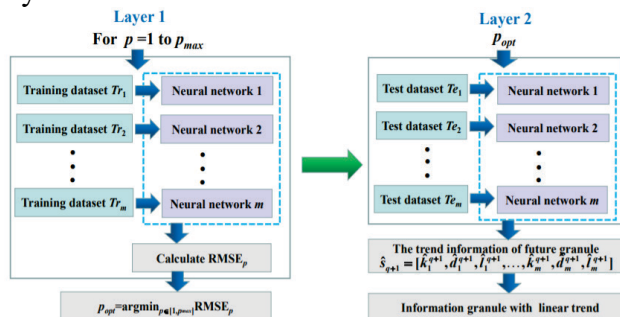
Както се вижда от фиг. 8, модела се състои от множество независими резервоари, всеки с различна рекурентна връзка. Най-горният резервоар е за прихващане на дългосрочни зависимости и "черти" във времевата поредица. Той е настроен за стъпка на "пропускане" (skip step) равна на три, така състояние 4 зависи директно от състояние 1 на системата. Обикновения резервоар в средата на схемата (typical reservoir) използва хипотези на Марков и състояние 4 зависи директно от състояние 3. Най-отдолу е поместен резервоара за краткосрочна памет. В случай, че неговият параметър е настроен на 3, то състояние 4 на системата ще зависи от предходните две (2 и 3). Наркая всички състояния от отделните резервоари се "слепват" в многомащабна временна картина и така се подават на изходния слой за крайна прогноза. Тази комплексна система е тествана с различни по характер данни - Среден брой на слънчевите петна, Лоренц, натоварване на електрическата мрежа на определен регион и др. Новият метод дава най-малка MSE спрямо класически ехо мрежи, както и такива с кратко или дългосрочна памет. Накрая са изведени зависимости между два от т.нар хиперпараметри на ехо мрежата - skip step и броя стъпки, които резервоара за кратковременни зависимости гледа назад. Като бъдещо разширение на системата се посочва възможността за прихващане на многовариантни времеви серии.

НМ с обратно разпространение на грешката и информационни гранули е показан в [11]. В началото метода сегментира входният времеви поток с цел изваждане на трендове и други специфики. Това е част от задължителната обработка за точна дългосрочна прогноза. Общата рамка за прогнозиране е показана на фиг. 9.



Фиг. 9 рамка за прогнозиране с информационни гранули [11].

В началото времевата поредица се разделя на множество по-малки времеви слотове и от тях се формират гранулите. В последствие от всяка гранула се извлича тренда чрез линейна обработка. След това сходните трендове се комбинират и се конструира нов набор данни с определени характеристики. Накрая е етапа за прогнозиране, състоящ се от две фази. В първата йерархия от НМ с обратно разпространение на грешката намира оптимален брой от предходните гранули, след което предсказването се конструира от рано получения оптимален брой гранули и така се изготвя прогнозния вектор. Предложената йерархията от НМ е показана на фиг. 10. В първият слой се тренират НМ от споменатата йерархия, като непрекъснато се следи RMSE. Във вторият слой се извлича информация за трендовете от бъдещите гранули.



Фиг. 10 йерархия на множество НМ за трениране и извличане на трендове [11].

Времевите редове срещу които е изпробвана системата са Mackey-Glass, цената на електрическата енергия, месечния брой

слънчеви петна, River Flow и реда на дневните температури. Спрямо другите алгоритми [11] показва най-ниска RMSE.

## ЗАКЛЮЧЕНИЕ

Независимо от прилагания математичен апарат, изготвянето на “предсказание” за времеви серии винаги ще е в областта на прогнозите и ще е свързано с грешки [3-5]. Последните тенденции са свързани с извличане на всевъзможни статистични величини на времевите редове. Те от своя страна биват подавани на сложни и комплексни алгоритми с помощта на който се генерира прогнозата [4-7]. Общото мнение на повечето автори, е че няма универсално решение за всички типове времеви редове. По скоро съществуват подходящи структури и алгоритми, които се справят по-добре при определени условия от други [3, 7, 8, 9].

## БЛАГОДАРНОСТИ

Този доклад е финансиран от Научно-изследователски сектор при Технически Университет – София.

## ЛИТЕРАТУРА

- [1] W. Huang, Y. Li and Y. Huang, "Deep Hybrid Neural Network and Improved Differential Neuroevolution for Chaotic Time Series Prediction," in IEEE Access, vol. 8, pp. 159552-159565, 2020, doi: 10.1109/ACCESS.2020.3020801.
- [2] T. H. H. Aldhyani, M. Alrasheedi, A. A. Alqarni, M. Y. Alzahrani and A. M. Bamhdi, "Intelligent Hybrid Model to Enhance Time Series Models for Predicting Network Traffic," in IEEE Access, vol. 8, pp. 130431-130451, 2020, doi: 10.1109/ACCESS.2020.3009169.
- [3] I. Z. Memon, S. Talpur, S. Narejo, A. Z. Junejo and E. F. Hassan, "Short-Term Prediction Model for Multi-currency Exchange Using Artificial Neural Network," 2020 3rd International Conference on Information and Computer Technologies (ICICT), San Jose, CA, USA, 2020, pp. 102-106, doi: 10.1109/ICICT50521.2020.00024.
- [4] Zhang, Daoqing & Jiang, Mingyan. (2020). Hetero-dimensional multitask neuroevolution for chaotic time series prediction. IEEE Access. PP. 1-1. 10.1109/ACCESS.2020.3007142.
- [5] F. Shen, J. Liu and K. Wu, "Multivariate Time Series Forecasting based on Elastic Net and High-Order Fuzzy Cognitive Maps: A Case

- Study on Human Action Prediction through EEG Signals," in IEEE Transactions on Fuzzy Systems, doi: 10.1109/TFUZZ.2020.2998513.
- [6] O. Ozyegen, S. Mohammadjafari, E. Kavurmacioglu, J. Maidens and A. B. Bener, "Experimental Results on the Impact of Memory in Neural Networks for Spectrum Prediction in Land Mobile Radio Bands," in IEEE Transactions on Cognitive Communications and Networking, vol. 6, no. 2, pp. 771-782, June 2020, doi: 10.1109/TCCN.2019.2958639.
- [7] H. K. Hoomod and Z. S. Amory, "Temperature Prediction Using Recurrent Neural Network for Internet of Things Room Controlling Application," 2020 5th International Conference on Communication and Electronics Systems (ICES), COIMBATORE, India, 2020, pp. 973-978, doi: 10.1109/ICES48766.2020.9137885.
- [8] S. Nihale, S. Sharma, L. Parashar and U. Singh, "Network Traffic Prediction Using Long Short-Term Memory," 2020 International Conference on Electronics and Sustainable Communication Systems (ICESC), Coimbatore, India, 2020, pp. 338-343, doi: 10.1109/ICESC48915.2020.9156045.
- [9] X. Wang and Y. Zhang, "Multi-Step-Ahead Time Series Prediction Method with Stacking LSTM Neural Network," 2020 3rd International Conference on Artificial Intelligence and Big Data (ICAIBD), Chengdu, China, 2020, pp. 51-55, doi: 10.1109/ICAIBD49809.2020.9137492.
- [10] K. Zheng, B. Qian, S. Li, Y. Xiao, W. Zhuang and Q. Ma, "Long-Short Term Echo State Network for Time Series Prediction," in IEEE Access, vol. 8, pp. 91961-91974, 2020, doi: 10.1109/ACCESS.2020.2994773.
- [11] W. Wang, W. L. Liu and H. Chen, "Information granules-based BP Neural Network for Long-term Prediction of Time Series," in IEEE Transactions on Fuzzy Systems, doi: 10.1109/TFUZZ.2020.3009764.