International Scientific Conference 20 UNITECH 26

INTERNATIONAL SCIENTIFIC CONFERENCE
19-21 November 2026
GABROVO

ИЗПОЛЗВАНЕ НА НЕВРОННИ МРЕЖИ ПРИ ОПТИМИЗИРАНЕ НА КАЧЕСТВОТО НА GSM КОМУНИКАЦИИТЕ

Ивелина Балабанова[1] **Тони Найденов[2]**

[1]Технически университет - Габрово, ул. „Хаджи Димитър“ № 4, Габрово, България
[2]Технически университет - Габрово, ул. „Хаджи Димитър“ № 4, Габрово, България
toni.naydenov@abv.bg

NEURAL NETWORKS USING TO OPTIMIZE THE QUALITY OF GSM COMMUNICATIONS

Ivelina Balabanova[1] **Toni Naydenov[2]**

[1]Technical University - Gabrovo, 4 “Hadji Dimitar” Str., Gabrovo, Bulgaria
[2]Technical University - Gabrovo, 4 “Hadji Dimitar” Str., Gabrovo, Bulgaria
toni.naydenov@abv.bg

Abstract
The paper presents the Use of Neural Networks in Optimizing the Quality of GSM Communications. Nowadays, with the growth of subscribers in cellular networks and the requirements for quality and high data transfer speeds, optimizing the quality of services of mobile operators is of key importance. For this purpose, we use neural networks and artificial intelligence to detect weak links and optimize them in order to improve the quality of service. For this purpose, traffic data for a given geographical region and a certain time are analyzed and resources are redirected in the network.

Keywords: Neural Networks; QoS Optimization; GSM Communications; Traffic Data.

ВЪВЕДЕНИЕ

Съвременните мобилни комуникации се превърнаха в критична инфраструктура за обществото, икономиката и индустрията. С нарастването на броя мобилни устройства, увеличаването на обема трафик и навлизането на IoT технологии, изискванията към качеството на GSM комуникациите стават все по-високи. Традиционните методи за управление, планиране и мониторинг на мрежите вече не са достатъчни, за да гарантират стабилност, надеждност и ефективно използване на наличните ресурси [1, 2].

На този фон в областта на телекомуникациите все по-широко навлизат методите на изкуствения интелект, в частност невронните мрежи. Те дават възможност за автоматизирано вземане на решения, прогнозиране, адаптивен контрол и оптимизация в реално време. В настоящия реферат се разглеждат видовете невронни мрежи, тяхното приложение в GSM мрежите, ключови модели за оптимизация на качеството, предизвикателства и бъдещи тенденции [3-5].

В доклада е синтезирана методика с насоки за ресурсното оптимизиране относно QoS в комуникациите чрез технологиите на Изкуствения интелект.

ИЗЛОЖЕНИЕ

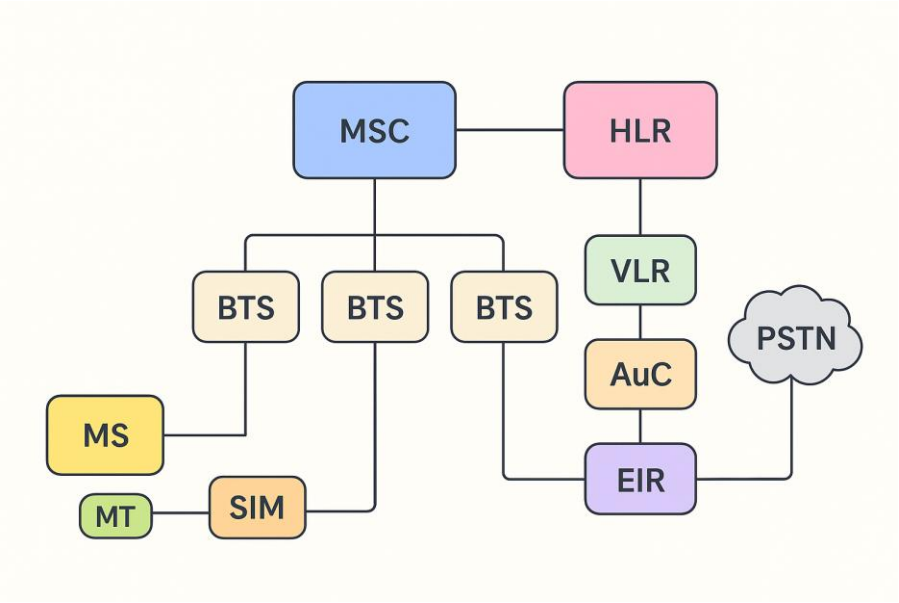
1. Основи на GSM комуникациите и показателите за качество

GSM (Global System for Mobile Communications) е втора генерация мо-

Print ISSN: 1313-230X, Online ISSN: 3033-1404

билна клетъчна система, използваща TDMA/FDMA принципи на разделяне на ресурсите. Макар днес да съществуват по-нови технологии, като UMTS, LTE и

Поддържането на тези показатели в оптимални граници е ключова задача за операторите.



Фиг.1 *Блокова схема на мобилна клетъчна мрежа*

5G, GSM продължава да бъде широко използвана, особено в IoT и машинната комуникация (Фиг. 1) [6-8].

1.1. Основни показатели за качество (QoS и QoE)

Оценката на мобилната мрежа включва набор от технически индикатори [1]:

- ***RxLev*** – мощност на приетия сигнал;
- ***RxQual*** – качество на сигнала, свързано с битовата грешка;
- ***BER/FER*** – ниво на грешки при предаване;
- ***Drop Call Rate (DCR)*** – процент отпаднали разговори;
- ***Call Setup Success Rate (CSSR)*** – успешни опити за установяване на разговор;
- ***Handover Success Rate*** – успешно преминаване между клетки;
- ***Throughput*** – пропускателна способност.

2. Невронни мрежи – концепции и разновидности

Невронните мрежи представляват математически модели, вдъхновени от биологичните неврони, способни да моделират сложни зависимости и вземане на решения.

2.1. Видове невронни мрежи, използвани в телекомуникациите

- ***Перцептронни мрежи (MLP)*** – подходящи за класификация и регресия;
- ***Рекурентни невронни мрежи (RNN, LSTM, GRU)*** – за анализ на времеви серии, например предвиждане на натоварване;
- ***Конволюционни невронни мрежи (CNN)*** – за обработка на изображения, но и за анализ на спектрални характеристики;
- ***Невронни мрежи за подсилено обучение (Reinforcement Learning – RL)*** – адаптивно управление и оптимизация в реално време;

- ***Графови невронни мрежи (GNN)*** – за анализ на сложни структури като клетъчни топологии [9-12].

3. Приложение на невронните мрежи за оптимизация на GSM мрежите

3.1. Управление на натоварването (Load Balancing)

При неравномерно разпределение на потребителите в клетките се появяват претоварвания, които водят до намаляване на качеството. Невронните мрежи могат да:

- анализират динамични модели на трафика;
- предвиждат бъдещи пикови натоварвания;
- препоръчват пренасочване на потребители към по-слабо натоварени клетки;
- оценяват вероятността от претоварване.

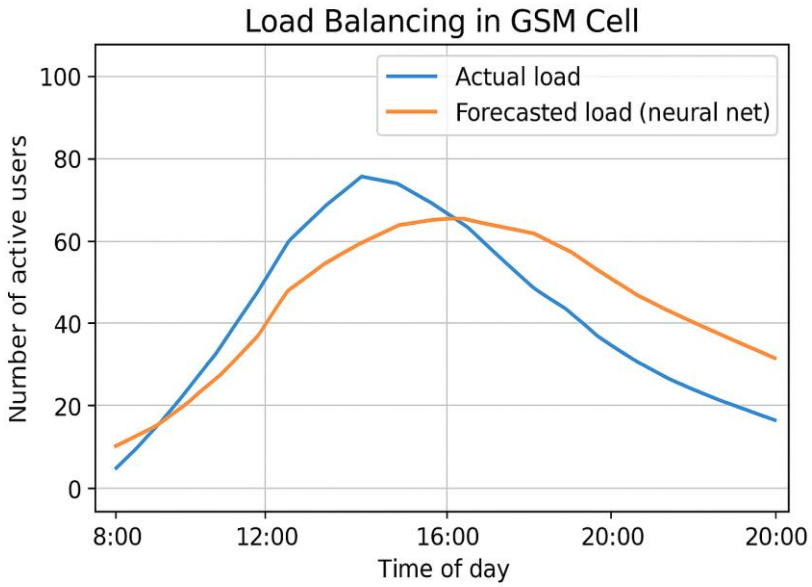
3.2. Оптимизация на параметрите за хендовер

Хендовърът е критична процедура, при която потребителят преминава между клетки. Неправилно настроени параметри водят до отпаднали разговори. С използване на RL модели операторите могат да:

- оптимизират праговете за хендовер;
- адаптират параметрите в зависимост от натоварването и качеството;
- намалят броя неуспешни или ненужни хендовъри.

3.3. Предвиждане и предотвратяване на отпаднали повиквания

Невронните мрежи могат да откриват зависимости между ниво на сигнал, натоварване и вероятност за отпадане.



***Фиг. 2**. Графика на текущото и прогнозното натоварване на GSM мрежа във времето от денонощието*

Рекурентните мрежи (LSTM) често се използват за прогнозиране на натоварването, тъй като улавят дългосрочни зависимости.

Предимства:

- ранно откриване на потенциални проблеми;
- превантивно преразпределяне на ресурси;

- ❖ поддръжка на мрежата на базата на прогнозни модели (Фиг. 2).

3.4. Автоматично откриване на аномалии и неизправности

Чрез CNN или автоенкодери се анализират:

- ❖ измервания от базови станции;
- ❖ ключови параметри на канала;
- ❖ абнормално високи нива на BER, DCR или RSSI.

Невронните мрежи позволяват откриване на аномалии, които трудно се идентифицират чрез класически статистически методи.

3.5. Оптимизация на радиочестотното планиране (RF Planning)

RF планирането е процес, включващ:

- ❖ позициониране на базови станции,
- ❖ избор на честоти,
- ❖ определяне на антени и параметри за покритие.

Невронните мрежи подпомагат:

- ❖ прогнозиране на зона на покритие;
- ❖ избор на оптимални антени;
- ❖ минимизиране на интерференцията;
- ❖ симулации на мрежата при различни конфигурации.

Графовите невронни мрежи се използват за моделиране на клетъчни структури като графи.

4. Подсилено обучение за самооптимизиращи се мрежи (SON)

Съвременните мобилни мрежи, включително GSM, използват автоматизирани SON системи. Подсиленото обучение дава възможност мрежата да "учи от опит".

4.1. Примерни SON задачи

- ❖ автоматична калибрация на параметрите;
- ❖ адаптация към променящи се условия;
- ❖ намаляване на енергийната консумация;
- ❖ оптимизация на честотните ресурси.

4.2. RL агенти в GSM

RL моделът получава:

- ❖ състояние – измервания от мрежата;
- ❖ действие – промяна на параметър (напр. хендовер прагове);
- ❖ награда – подобрение или влошаване на QoS.

По този начин мрежата се самооптимизира без необходимост от човешка намеса.

5. Оптимизация на качеството чрез анализ на сигналите

5.1. Откриване на интерференция

Интерференцията е една от най-големите причини за ниско качество в GSM. Невронните мрежи анализират спектрални характеристики и автоматично идентифицират:

- ❖ co-channel интерференция;
- ❖ съседно-канална интерференция;
- ❖ нелинейни смущения.

5.2. Подобряване на качеството чрез филтриране и корекция

Някои модели (CNN, RNN) могат да работят директно със сигнала, за да:

- ❖ подобрят BER;
- ❖ коригират шум;
- ❖ възстановят унищожена част от информацията.

6. Предимства от внедряване на невронни мрежи в GSM мрежи

6.1. Технически предимства

- ❖ по-високо качество на връзката;
- ❖ намален брой откази и отпаднали разговори;

- по-добро покритие;
- оптимално използване на честотния ресурс;
- подобрени параметри за хендовер.

6.2. Икономически предимства

- по-ниски разходи за поддръжка;
- по-малко нужда от човешка намеса;
- бързо откриване на повреди;
- по-ефективно използване на инфраструктурата.

6.3. Потребителски ползи

- по-високо качество на разговорите;
- по-бърза и надеждна връзка;
- по-малко прекъсвания;
- стабилно покритие в движение.

7. Предизвикателства и ограничения

7.1. Събиране и обработка на големи данни

Нужни са огромни количества данни, които често включват чувствителна информация.

7.2. Обучение и изчислителна сложност

Невронните мрежи изискват значителни ресурси и оптимизация.

7.3. Сложност на интеграцията

Съществуващите GSM мрежи често работят с остаряла инфраструктура.

7.4. Обяснимост на моделите

Дълбоките модели трудно се интерпретират, което затруднява операторите.

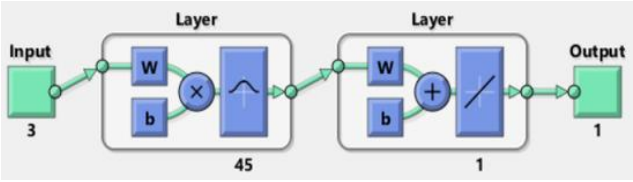
8. Оптимизиране на времето за чакане на обслужване на потребителски заявки

Съществено изискване в осблужващите сървърни станции в комуникационните звена е оптимизирането на времето за чакане на заявки в опашката. Това налага използването на различни невронни инструменти.

Една от потенциалните възможности за това се явава интегрирането на Radial Basis Neural Networks (RBNNs). В тази връзка в Таблица 1 са представени данни относно извеждане на RBNN модел за оптизиране на „средното време за чакане в опашката“ при входни метрики „средна скорост на постъпване“, „средно обслужващо време“ и „максимален праг за чакане в опашката“. Данните обхващат експериментални процедури относно анализ на поведението на „средноквадратичната грешка“ спрямо стъпково нарастване на метрика Spread – (специфичен параметър за заложената функция в радиално базисния слой на RBNNs).

Таблица 1. Поведение на RBNN с промяна на Spread

Метрика Spread	Средноквадратична грешка
0,90	5.8093e-29
0,91	2.7999e-29
0,92	3.8788e-29
0,93	**2.6619e-29**
0,94	4.0602e-29
0,95	4.7647e-29
0,96	1.0889e-28
0,97	1.4723e-28
0,98	9.4895e-29
0,99	1.2047e-28



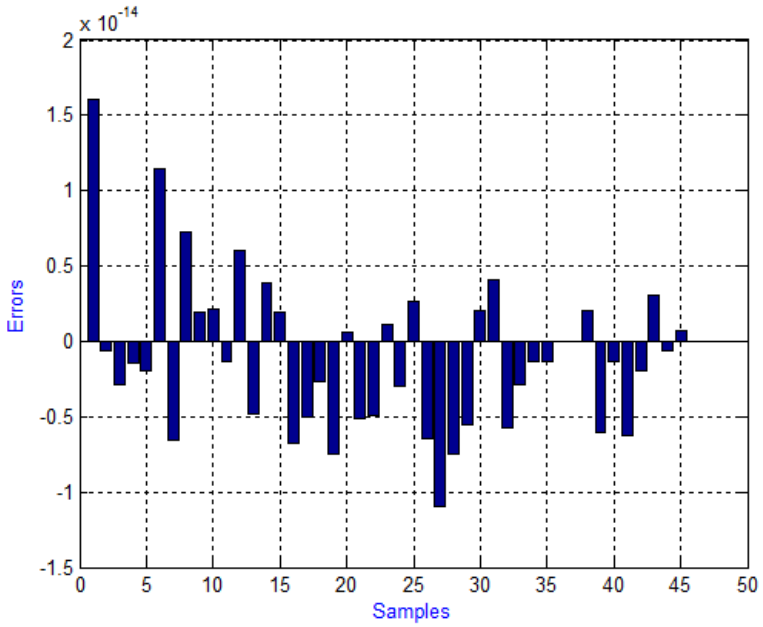
Фиг. 3. *RBNN модел за оптимизиране на времето на чакане на потребителски заявки*

Според проведените изследвания най-висок праг на грешката 1.2047e-28 е установен при крайна стойност на Spread. Удовлетворяваща стойност 2.6619e-29 е постигната за Spread = 0.93, даващо основание за избор на посочения RBNN модел (Фиг. 3.) Фигура 4 показва вариациите между теоретичните при невронно

обучение и изходните прогнозни оптимални стойности на „средното време за чакане в опашката“. Указаните варации попадат в значително нисък диапазон от 1.0991e-14 до 1.6074e-14, потвърждаващо качествата на RBNN модела.

9. Бъдещи тенденции

- *Интегриране на GNN и RL за напълно автономни мрежи.*
- *Комбиниране на GSM и IoT с AI за надеждна M2M комуникация.*
- *Хибридни AI системи за прогнозиране, планировка и оптимизация в реално време.*
- *5G/6G технологии ще използват още по-силно невронни мрежи, но GSM ще остане важен в индустрията.*



***Фиг. 4**. Вариации на разликите между теоретичните и прогнозните стойности на средното време за чакане в опашката*

ЗАКЛЮЧЕНИЕ

Невронните мрежи оказват значително влияние върху развитието на мобилните комуникации, включително и върху традиционните GSM системи. Благодарение на способността си да обработват големи обеми данни, да откриват скрити зависимости и да извършват прогнозен анализ, те предоставят ефективни средства за оптимизация на качеството на услугите. Чрез интегрирането им в GSM мрежите операторите могат да подобрят надеждността, да намалят интерференцията, да адаптират параметрите в реално време и да внедрят автоматизирани системи за управление.

Изготвената концепция за оптимизация на ресурсите е съобразена спрямо следните стандарти:

- 3GPP TS 45.xx – серия стандарти за GSM/EDGE радио достъп.
- ETSI GSM Standards – официална спецификация за GSM (ETSI Technical Specifications).
- 3GPP TR 36.902 – SON (Self-Organizing Networks) начални концепции.
- ITU-R Reports on Quality of Service & Mobile Network Performance.

Въпреки предизвикателствата, перспективите са изключително благоприятни, а развитието на AI обещава още по-ефективни и автономни мобилни мрежи в бъдеще.

БЛАГОДАРНОСТИ: *Изследванията в доклада са финансирани във връзка с из-*

пълнение на Проект „№ НИП2026-18: Подобряване на качеството и киберсигурността при мрежова диагностика в комуникациите с помощта на Изкуствен интелект“.

ЛИТЕРАТУРА

[1] Bishop C. Neural networks for pattern recognition. Oxford: Oxford University Press, 1995.

[2] Mohamed A. (et al.). Machine learning for wireless communications: A survey. IEEE Communications Surveys & Tutorials 2021;1(1):1-5.

[3] Zibar D. (et al.). Machine learning techniques in communication systems. IEEE Journal of Lightwave Technology 2017;34(6):1-5.

[4] Haykin S. Neural networks and learning machines. London: Pearson, 2009.

[5] Tang J, Wong K. Mobile networks optimization. Berlin: Springer, 2018.

[6] Amirijoo A. (et al.). Use of neural networks for handover optimization in GSM networks. IEEE ICC 2015;6(1):1-4.

[7] Jansen S. Anomaly detection in cellular networks using deep learning. IEEE Transactions on Network and Service Management 2019;3(1):1-4.

[8] Rappaport T. Wireless communications: principles and practice. New Jersey: Prentice Hall, 2002.

[9] Vesilo R. Self-Organizing Networks (SON) in radio access networks. New York: Wiley and Sons Inc., 2017.

[10] Venkataraman H, Muntean G. Machine learning in wireless networks. Berlin: Springer, 2021.

[11] Nasri R. (et al.). Load balancing in cellular networks using deep reinforcement learning. IEEE Transactions on Wireless Communications 2020;5(1):1-4.

[12] O’Shea T, Hoydis J. An introduction to deep learning for the physical layer,” IEEE Transactions on Cognitive Communications and Networking 2017;3(4):563-575.