



# **ТЕХНИЧЕСКИ УНИВЕРСИТЕТ - ГАБРОВО**

**Факултет “Електротехника и електроника”**

**Катедра “Комуникационна техника и технологии”**

**маг. инж. ДИОНИСИЯ АНТИМОС ДАСКАЛАКИ**

## **ДЕТЕКТИРАНЕ И АНАЛИЗ ПРЕЗ КОМУНИКАЦИОННИ КАНАЛИ НА ФИЗИЧЕСКИ ХАРАКТЕРИСТИКИ НА МЕТАЛИТЕ, ЧРЕЗ ИЗПОЛЗВАНЕ НА УЛТРАЗВУКОВИ СЕНЗОРИ**

### **А В Т О Р Е Ф Е Р А Т**

на дисертационен труд за присъждане  
на образователна и научна степен “**доктор**”

Област на висше образование: 5. Технически науки

Професионално направление: 5.3. Комуникационна и компютърна техника

по **Докторска програма: “Комуникационни мрежи и системи”**

**Научен ръководител:**

проф. д-р инж. Станимир Михайлов Садинов

**Рецензенти:**

1. проф. д-р инж. Райчо Тодоров Иларионов
2. проф. д-р инж. Валентина Илиева Маркова

гр. Габрово

2022 г.

Дисертационният труд е обсъден и насочен за официална защита на заседание на Разширен катедрен съвет на катедра „Комуникационна техника и технологии“ към факултет „Електротехника и електроника“ на Технически университет – Габрово, проведен на 28.04.2022 г.

Дисертационният труд съдържа 152 страници. Научното съдържание е представено в увод и четири глави, и включва 116 фигури и 30 таблици. Цитирани са 132 литературни източника. Номерацията на фигурите, таблиците и формулите в автореферата е в съответствие с тази в дисертацията.

Изследванията по дисертационния труд са извършени в катедра „Комуникационна техника и технологии“ към факултет „Електротехника и електроника“ на Технически университет – Габрово и на територията на гр. Габрово.

Официалната защита на дисертационния труд ще се състои на 22.07.2022 г. от 14 ч. в Заседателна зала, сграда Ректорат на Технически университет – Габрово.

Материалите по защитата са на разположение за интересуващите се в кабинет 3209, корпус №3 на Технически университет – Габрово.

Рецензиите и становищата на членовете на научното жури и авторефератът са публикувани на сайта на университета: [www.tugab.bg](http://www.tugab.bg).

© Дионисия Антимос Даскалаки – автор, 2022

e-mail: [d\\_daskalaki@yahoo.gr](mailto:d_daskalaki@yahoo.gr)

Заглавие: Детектиране и анализ през комуникационни канали на физически характеристики на металите, чрез използване на ултразвукови сензори

Тираж: 15 бр. (Бълг. език)

Място на отпечатване: Университетско издателство „Васил Априлов“ при ТУ - Габрово

## **I. ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД**

### **Актуалност на проблема:**

Измерванията на силови натоварвания, приложени върху метални детайли, модули, конструкции и съоръжения, е особено актуален проблем в разнообразие от приложения в различни сектори от индустрията. Тук могат да бъдат посочени:

- ❖ Машиностроене и Металургия при изработка и тестване на метални компоненти и функционални конструкции;
- ❖ Строителство и строително-ремонтни дейности;
- ❖ Корабостроене и Автомобилостроене;
- ❖ Железопътен транспорт;
- ❖ Контрол на летателни апарати;
- ❖ Аграрни дейности и Селско стопанство;
- ❖ Изработка на изделия, компоненти и сложни системи за изпитване на биомедицинско оборудване с предназначение в различни сектори на медицината;
- ❖ Комуникации при полагане, изграждане и поддръжка на експлоатацията на комуникационни кабелни трасета, мониторинг на механичните натоварвания на базови и мобилни станции и т.н.

Имайки предвид нежеланото наслагване на различни смущаващи въздействия и шумове в комуникационните канали за връзка, важна задача, имаща отношение към качеството на регистрирана измервателна информация, е обезпечаването на преноса на данни от входните възли с функционални преобразуватели на използваните сензорни мрежи и системи. Това е необходимо във връзка с адекватното функциониране и адаптивност на последващите системни модули за визуализация и коректен анализ на обработваните информационни масиви от процедури по параметричен отдалечен мониторинг. За целта е необходимо да се използват подходящи статистически инструменти и апарати за редукция на шума, диагностика на типа и степента на въздействие, както и прогнозен анализ на неговата количествена измеримост по отношение на анализираната измервателна информация.

Друг съществен момент се свързва с определяне на обема на трафика от сензорни данни и специфична параметрична информация, които може да бъде обслужен от страна на информационно-комуникационните модули при тяхно проектиране и оптимизиране на системните им ресурси. Относно това могат да бъдат модифицирани и създадени подходи за качествен и количествен анализ с адаптиране на методи и алгоритми от приложната статистика и изкуствения интелект. Тук възниква необходимостта от търсене и определяне на подходящи видове изкуствени невронни мрежи, обучаващи алгоритми и параметри, критерии за тяхна оценка и процедури по верификация, потвърждаващи достоверността на избора на конкретен апарат.

### **Методи на изследване:**

За постигане на целта и поставените задачи в изследването се прилага технологията на изкуствения интелект и класически регресионен анализ при извличане на знания от данни при обработка на измервателна сензорна информация във връзка с приложени сили на натоварване, нежелани шумове и преминаващия обслужван трафик в комуникационните канали за връзка.

### **Новости:**

Предложена е методика за идентификация на работни измервателни преобразуватели, типове смущаващи въздействия и количествено определяне на сили на въздействия върху

изпитвани метални образци и прогнозен обслужван трафик от измервателни и служебни данни на основата на изкуствен интелект и различни алгоритми на невронно обучение.

### **Цел и задачи на изследването:**

*Целта* на дисертационния труд се състои в разработване на софтуерна мониторингова система за измерване и изследване на приложени сили върху метални детайли, обекти и конструкции с обезпечаване на преносната среда и обработката на постъпващия трафик на регистрирани измервателни данни на сензорни данни интегриране на концепцията за качествен и количествен на информацията чрез изкуствен интелект. Във връзка с дефинираната цел на дисертационния труд се поставят следните *задачи за изпълнение*:

1. Да се извърши обучение и синтез на изкуствени невронни мрежи на имитирани шумови въздействия, наслагвани при предаване на сигнали в комуникационни канали за връзка в симулационна среда при Levenberg-Marquardt обучение при експериментиране с функциите на активация.
2. Да се селектират модели за идентификация на добавени въздействия при предаване на цифрови сигнали в електрониката, автоматиката и комуникациите на основата на изкуствени невронни мрежи при опериране с Levenberg-Marquardt обучаващ алгоритъм с експериментиране с функциите на активация.
3. Да се проведат обучаващи процедури на изкуствени невронни мрежи с право разпространение на сигналите и обратно разпространение на грешката при Scaled Conjugate Gradient алгоритъм на обучение за разпознаване на типа на смущаващите въздействия в комуникационни канали за връзка.
4. Да се проектира и тества работоспособността на система за измерване на сили, приложени върху изпитвани метални детайли, с включени звена за сигнална обработка и статистически анализ на основата на концепцията за „виртуална лаборатория“.
5. Да се създадат невронни модели за разпознаване на работни измервателни средства за регистрация на сили върху метални обекти на базата на SCG и LM обучаващи алгоритми при подбор на входните променливи, приложени към моделите.
6. Да се синтезират и проведе верификация на модели за прогнозен анализ на приложени силови въздействия върху метални детайли, създадени на базата на изкуствен интелект при Levenberg-Marquardt обучаващ алгоритъм.
7. Да се изведат линейни регресионни модели за прогнозен анализ на приложени сили върху метални обекти при различен брой включени работни измервателни преобразователи.
8. Да се изведат математически модели от различна степен на базата на регресионен анализ за прогнозиране на количеството обработени заявки с пакетна информация и времето за тяхно обслужване при имитационно моделирани телекомуникационни системи.
9. Да се реализират процедури по създаване, оценка и верификация и обобщени регресионни невронни мрежи и FCNN архитектури за прогнозен анализ на потенциалния брой клиентски заявки с пакетни данни при експериментиране с използваните управляемите фактори.
10. Да се синтезират FFNN невронни модели за прогнозен анализ на потенциалния обработван трафик от клиентски заявки с пакетни данни при различни комбинации от управляемите фактори и обучаващи алгоритми – Levenberg-Marquardt, Bayesian Regularization и Scaled Conjugate Gradient.

### **Предмет и обект на изследване на дисертационния труд:**

Дисертационният труд разглежда посочените задачи като единна съвкупност в извършване на последователни изследвания, насочени към създаване, синтезиране и

извеждане на модели за идентификация и прогнозен анализ при опериране със симулационни и реално получени опитни данни. Разглежда се следната **предметна област** на изследване „индустриални направления за изпитване на метални обекти с интеграция на информационно-комуникационните технологии“.

Съобразно така дефинираната област е формирана насоченост към следния **обект на изследване** „система за изпитване на метални обекти, подложени на различни натоварвания, и обезпечаване на процесите при пренос на сигнали по отношение на минимизация на шумови и случайни въздействия и планиране на обема от обработени заявки, съдържащи измервателна и специфична информация“.

### Апробация на дисертационния труд:

Основните етапи от разработване на дисертационния труд са представени на международни научни конференции в Технически университет – Габрово, Технически колеж Ловеч, Международна научна конференция по комуникации, информатика, електроника и енергийни системи „СIEES“, международни списания „Journal of Engineering Science and Technology Review“ и „Advances in Intelligent Systems and Computing“ с индексация в международни бази данни **Scopus** и **IEEE**.

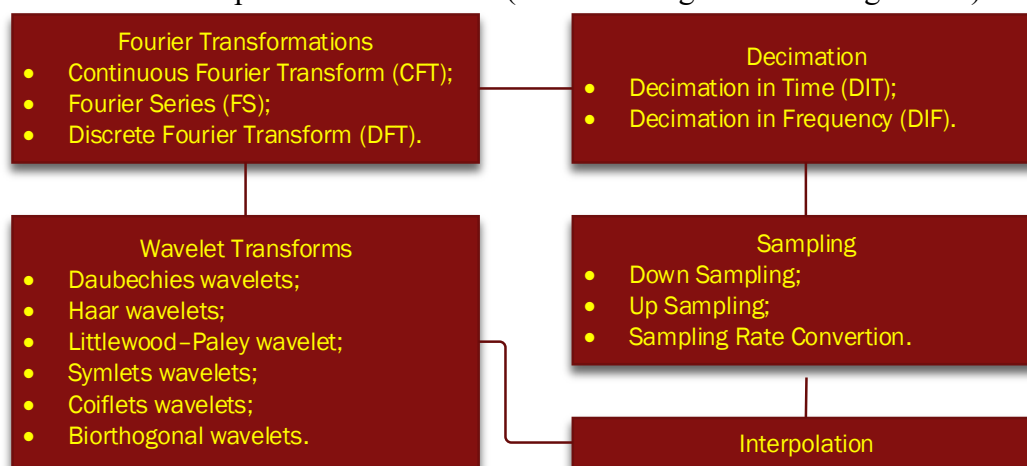
## II. КРАТКО СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

### ГЛАВА I. СЕНЗОРНИ ТЕХНИЧЕСКИ СРЕДСТВА И AI БАЗИРАНИ МОДЕЛИ ЗА АНАЛИЗ НА ПРЕДАВАНИ СИГНАЛИ И ПАРАМЕТРИЧНА ИНФОРМАЦИЯ

#### 1.3. Прилагани технически подходи за цифрова обработка на сигнали и редуциране на шумове в комуникационните канали за връзка

Сигналната обработка може да бъде разгледана като съвкупност от процеси на последователно преобразуване на сигнали с цел редуциране на ефекта от шумове и подобряване на качеството. Прилагат се различни методи за обработка, които могат да бъдат обособени в следните категории:

- ✚ Аналогова обработка на сигнали (Analog Signal Processing - ASP);
- ✚ Цифрова обработка на сигнали (Digital Signal Processing - DSP);
- ✚ Обработка на непрекъснати сигнали във времето;
- ✚ Обработка на дискретни сигнали във времето;
- ✚ Нелинейна обработка на сигнали (Nonlinear Signal Processing – NSP).

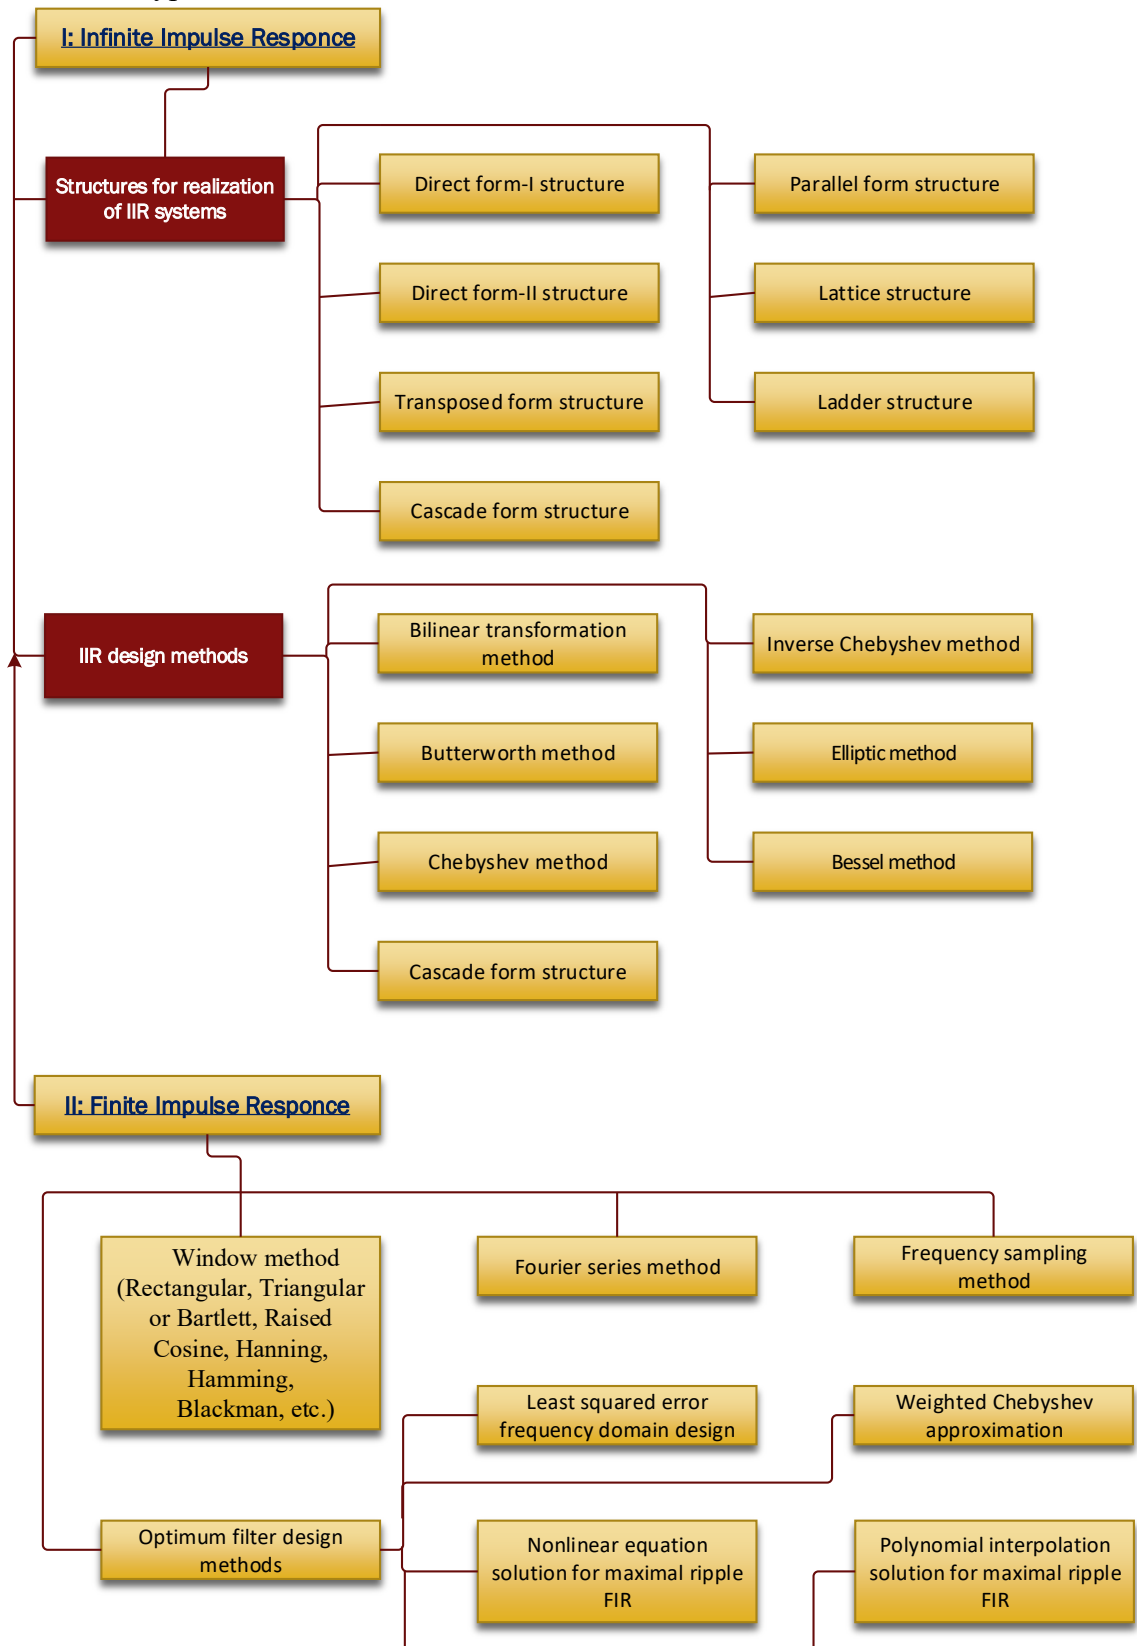


*Фиг. 1.11. Някои по-известни технически подходи за цифрова обработка на сигнали*

От своя страна DSP методите се разделят на:

- ✚ Непараметрични методи:
  - Анализ в честотната област;
  - Анализ във времевата област.

- ✚ Параметрични методи:
  - Модели със синусоидални функции;
  - Стохастични модели.
- ✚ Хибридни методи:
  - Комбинирани и Иновативни методи;
  - Рекурсивни методи.



Фиг. 1.12. Методи за проектиране на IIR и FIR филтриращи звена

DSP техническите подходи включват широк спектър като някои от по-известните са представени на фиг. 1.11.

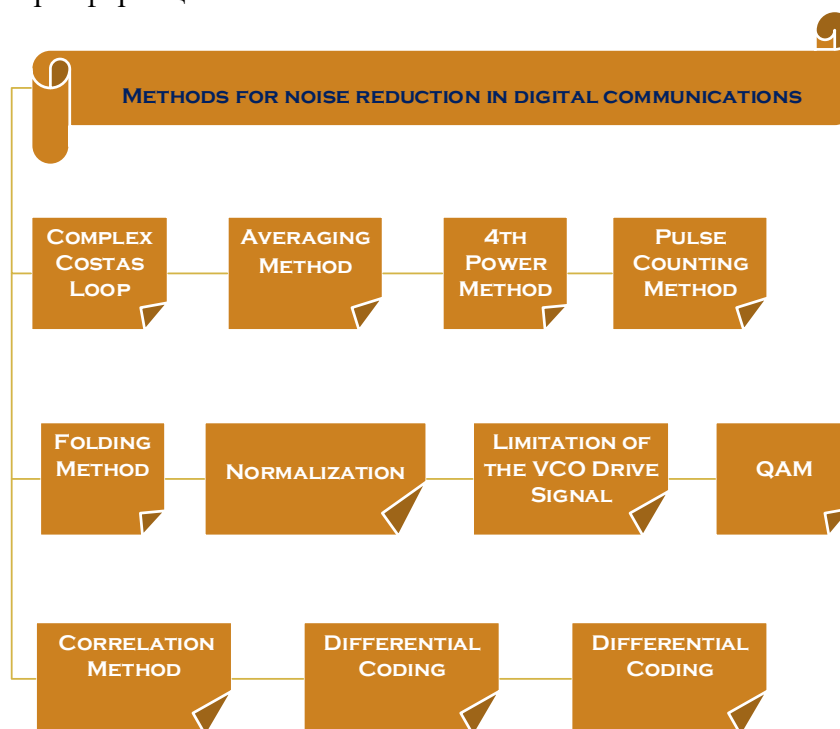
Съществен проблем в комуникациите са възникналите шумове в каналите за връзка при предаване на сигнали водят до съществени изменения в тяхната форма, независимо дали са аналогови или цифрови. Могат да възникнат и да бъдат насложени към сигналите White Noise (WN), Correlated Noise (CN) и други типове въздействия. Това налага прилагане на различни методи за филтрация, които могат да бъдат групирани в две основни категории:

- ✚ Infinite Impulse Response филтри – IIR звена (филтри с безкрайна импулсна характеристика);
- ✚ Finite Impulse Response филтри – FIR звена (филтри с крайна импулсна характеристика),

които са представени на фиг. 1.12.

Друга възможност за редуциране на ефекта от влиянието на шумове и подобряване на качеството на предавани сигнали в силно засегнати комуникационни канали за връзка се свързва с използване на:

- ✚ методи за синхронно детектиране;
- ✚ технически подходи за разширен спектрален анализ;
- ✚ комплексни периодични сигнали;
- ✚ уейвлет трансформация.



**Фиг. 1.13.** Методи за потискане на ефекта на шумове при системни устройства в комуникациите

Подобряването на специфичното съотношение „сигнал-шум“ с помощта на синтез на филтри за линейно прогнозиране и адаптивни цифрови филтри също се разглежда като техническо средство в тази посока. Прилагането на технически подходи за стабилизация на минимална средноквадратична грешка постигат удовлетворяващи нива на всички нива на шум в различни категории комуникационни системи. Съчетаването на технологиите за множествен достъп до комуникационните канали TDMA, OFDMA, FDMA при реализация на итеративни комуникационни приемници може да постигне значително да потисне възникнали нелинейни изкривявания. Ефекта от нежелани смущаващи въздействия може

също да бъде компенсиран чрез метод, комбиниращ подходите - Дискретна косинусова трансформация (Discrete Cosine Transform - DCT) и Дискретна синусоидална трансформация Discrete Sine Transform (DST).

Погледнато в различен аспект съществен проблем в редица комуникационни устройства се свързва с ограничаване на чувствителността им към шумове. Това налага използване на методи за постигане на този ефект. За целта на фиг. 1.13 е направена систематизация, засягаща основно сферата на цифровите комуникации.

## **1.5. Измерване на силови въздействия. Сензорни елементи**

### **1.5.1. Сфери на приложение на измерванията на сили върху обекти**

Измерванията на сили върху детайли и развитието на технологиите по отношение на използваните технически сензорни елементи и измервателни средства намира все по-широко разпространение в различни области на индустрията. Проблемът е особено засегнат през отделните етапи от *производство* и *изпитване на стомана* в големи металургични компании и предприятия. Освен при производство на стомана други индустриални направления, които могат да бъдат посочени са:

- ✚ *Агрикултурна индустрия;*
- ✚ *Сложни системи за изпитване на натоварванията в огромни по габарити сложни метални конструкции и съоразения като мостове и кранове;*
- ✚ *Автомобилна индустрия – товарни превозни средства и платформи;*
- ✚ *Железопътен транспорт – изпитване на задвижващи механизми, детектиране на възпламеняване в дизеловите двигатели на локомотиви, и т.н..*

Актуална сфера на приложение, която разглежда задачата за мониторинг на силови натоварвания и интеграция на измервателни сензорни, е медицината във връзка с производството на серия медицински изделия и системи. Тук могат да посочени:

- ✚ *Амбулаторни системи за дозиране на лекарства;*
- ✚ *Прецизно оборудване за хирургичеки интервенции;*
- ✚ *Помпи за прокарване на физиологични разтвори;*
- ✚ *Натоварване на различни компоненти от сложно медицинско оборудване.*

Друга съвременна и интересна област на приложение са *биомедицинските изследвания* при установяване на степен на сила при анализ на пръстови отпечатъци при докосване и натиск, оценка на клетъчния растеж, мониторинг на налягането в разнообразни технически средства за изследване.

### **1.5.2. Критерии за избор, калибриране и чувствителност на сензори за измерване на силови въздействия**

Подборът на конкретен тип сензори за измерване на сила е необходимо да бъде съобразен, както със спецификата на обекта на изпитване и средата на експеримента, така и с някои основни базисни критерии, респективно:

- ✚ *Ниво на изходния сигнал при номинално натоварване;*
- ✚ *Максимална нелинейност;*
- ✚ *Степен на плъзгане/свързване към контактния интерфейс;*
- ✚ *Маса на сензорния елемент.*

На следващ етап могат да бъдат дефинирани критерии за избор на цялостна система за измерване на сили на въздействие върху обекти, посочени на фиг. 1.17.

Съществен аспект, свързан с достоверността на измервателните данни и точността на измерванията, е коректността на сензорно калибриране, което преминава през три етапа:

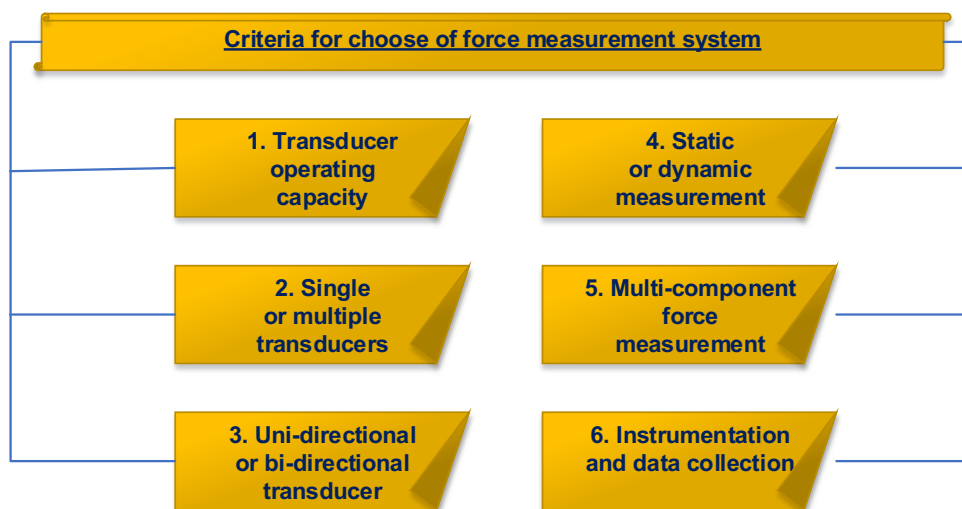
- ❖ *Специфициране на калибровъчния процес;*
- ❖ *Извършване на калибровъчните процедури;*
- ❖ *Анализ на калибрираните данни.*

Първият от етапите регламентира следните актуални въпроси:

- ✚ *Калибриране конкретно на място или в лабораторни условия?*



- ✚ Калибриране на цялата система или само на преобразувателя?
- ✚ Налице ли е заявка за допълнителна корекция?
- ✚ Какво е изискваното ниво за допустимо отклонение?
- ✚ Какво е направлението и диапазона на действие на измерваната сила?
- ✚ Какви са условията на натоварване за конкретното приложение?
- ✚ Какъв е температурният диапазон за приложението?



*Фиг. 1.17. Критерии за избор на измервателна система за мониторинг на силови въздействия върху обекти*

Наборът от типове изходни електрически напрежения, подлежащи на измерване и регистрация, както и взети предвид при процедури по калибриране на сензори за сила, може да съдържа, както следва:

- ✚ Стандартизирани специфицирани отклонения;
- ✚ Пропадане на характеристиките;
- ✚ Системна разделителна способност;
- ✚ Хистерезис;
- ✚ Ненатоварване на сензорния елемент;
- ✚ Повторяемост на измервателните резултати;
- ✚ Температура на околната среда.

Съгласно литературни източници за целите на калибровъчния процес могат да бъдат използвани следните типове Force Calibration Machines (FCM), респективно:

- ✚ Пълна товароподемност/Собствено сензорно тегло;
- ✚ Хидравлично усилване;
- ✚ Лостово усилване;
- ✚ Компаратор с един до три еталонни преобразователи за сила.

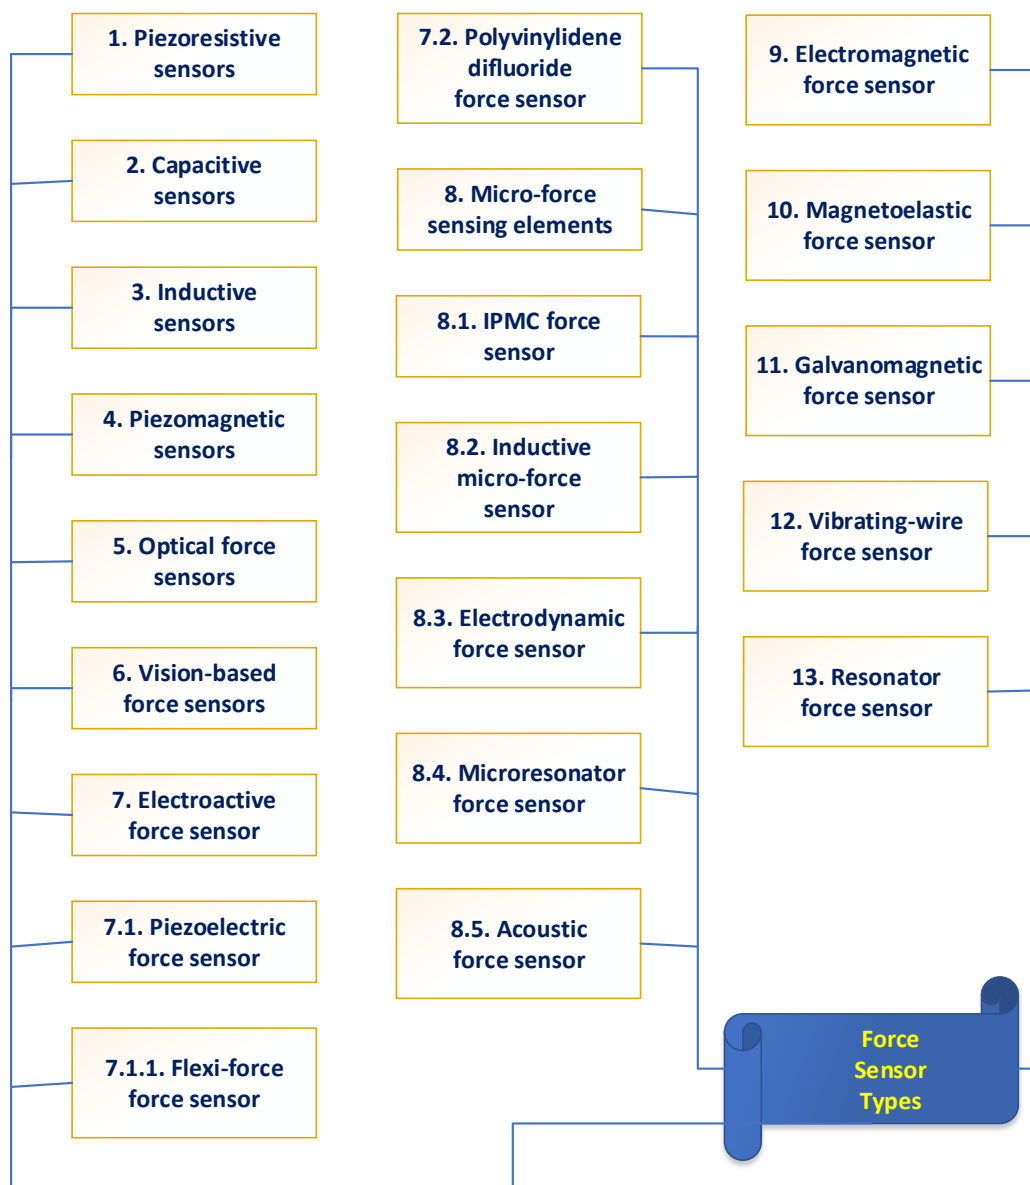
Важна характеристика на прилаганите сензорни елементи в постановки за мониторинг на сили на въздействие върху изпитвани метални обекти е „Чувствителността“. Указаният показател за качество на измервателните процедури може да бъде съществено повлиян от следните фактори:

- ✚ Неправилно геометрично позициониране на сензорния елемент по време на монтаж;
- ✚ Неоптимално разположение на сензорите;
- ✚ Промяна на свойствата на елементите;
- ✚ Наличие на паразитни натоварвания и т.н.

В тези случаи възниква необходимост от поставяне на компенсирани компоненти в моментите на деформация и огъване.

### 1.5.3. Категоризация на сензорите за следене и регистрация на силови въздействия

Научните изследвания дават основание за формиране на типови категории сензорни технически средства за измерване на сила според различни признаци, но най-общо може да бъде представена категоризацията, дадена на фиг. 1.18.



Фиг. 1.18. Категории сензори за следене и регистрация на силови натоварвания

### 1.6. Системни технически решения при измервания на силови натоварвания върху метали и измервателни технически средства

Според изследванията измервателните средства за следене и регистрация на силови натоварвания са разделени в следните категории:

- ✚ „Преки измервания“, към която спадат:
  - ✓ Преобразуватели за сила;
  - ✓ Товарни клетки;
  - ✓ Динамометри.

- ✚ „Косвени измервания“, към която могат да се причислят: Сензори, наречени „измервателни прибори за сила/опън/натиск“ - strain gauges, които обикновено са монтирани към механични системи.

Могат да бъдат дефинирани следните индустриални области, касаещи измерванията на сили върху метални структури и конструкции:

- ✚ *Определяне на силите на машината в процеса на валцуване стоманодобивна промишленост;*
- ✚ *Оптимално и контролирано прилагане на пресоването сили върху метална плоча и листов материал;*
- ✚ *Машины за изпитване на материали, използвани при механични изпитвания като се прилага за първоначално производство и контрол на последващи операции с продукти;*
- ✚ *Механично изпитване на стоманени материали и строителни продукти, използвани в строителството;*
- ✚ *Прилагане на сили на опън върху хартия, пластмаса, рулони от филми и ламинат;*
- ✚ *Сили на рязане върху метална плоча и листов материал;*
- ✚ *Определяне на силите на куката и въжето при закотвен за кораби и танкери;*
- ✚ *Контрол на претоварване в кули и мостови кранове и асансьори;*
- ✚ *Определяне на силите, които се прилагат върху колелата на камиона на павирани пътни трасета;*
- ✚ *Измерване на силите, идващи към краката на кулата, на петролни рафинерии;*
- ✚ *Сили, приложени за регулиране на напрежението на кабели при тяхно полагане и монтаж;*
- ✚ *Сили, приложени при подводно полагане на тръбни съоръжения [47].*

Съгласно проучванията измервателните средства за косвени измервания могат да бъдат разделени на „метални“ и „полупроводникови“. Металните прибори от своя страна се подразделят в следните групи:

- ✚ Метални тънкослойни сензори;
- ✚ Фолиеве измервателни прибори;
- ✚ Измервателни прибори с метално покритие.

Те са подходящи за мониторинг на продължителни динамични натоварвания, докато полупроводниковите за регистрация на натоварвания, приложени в ограничена площ, поради своята висока чувствителност .

Съществуват редица научни изследвания, които са насочени към следенето и измерване на предизвиканите деформации и асоциираните с тях приложени сили на натоварвания. В някои изследвания е разгледана употребата на слените технически средства:

- ✚ Фотограметрични измервателни системи за сила/опън/натиск;
- ✚ Фолиини измервателни прибори за сила/опън/натиск;
- ✚ Фибро-оптични измервателни прибори за сила/опън/натиск като FSG и FBG сензорни елементи,

чрез които са регистрирани сили от порядъка на 26 kN. Друга публикация разглежда компютърно-базирана система известна като „Computerized Dynamometer“ позволяващ включване на 8 сензора, базирани на товарни клетки тип S. В апаратната част са включени:

- ✚ Механичен динамометър;
- ✚ Цифров динамометър с вътрешни сензори;
- ✚ Цифров динамометър с външни сензори.

Събирането на сензорни данни е извършено чрез многофункционален модул, разполагащ с USB драйвер, АЦП, мултиплексор, усилватели и филтриращи звена непосредствено до използваните сензори. В някои проучвания се извършва проектиране на

специализирани Ground Reaction Force (GRF) измервателна системи, използващи двуосни сензори за сила, базирани на оптичен сензорен механизъм. Тук физичната интерференция между две оси на персонализирания сензор е била сведена до минимум от независимия сензор чрез прилагане на конзолна структура за двете оси и стабилни хистерезис и повторяемост на специализирания сензор. Сценарий на експеримент за измерване на двойка приложени сили и вибрационни въздействия са разгледани в част от проучванията в областта. Измерванията са извършени чрез:

- ✚ сензорни матрици за налягане;
- ✚ сензори за ускорение.

Друго изследване е насочено към оценка на системи за измерване на силови въздействия върху метални обекти при приложение на технически подходи с използване на:

- ✚ Polyvinylidene fluoride (PVDF) преобразуватели за сила, които впоследствие в хода на експеримента са модифицирани като насложени с PVDF измервателни прибори за сила/опън;
- ✚ Миниатюрни пиезоелектрически товарни клетки, разполагащи с кварцови преобразуватели за динамични измервания.

Технически средства от вида „strain gauges“ са използвани за мониторинг на статичната и динамичната реакция на метални конструнструкции. Измервателните прибори са били позиционирани на различни места във вътрешността на констрункциите като за следене на техните състояния е използвана DAC USB системи. В е реализирана Arduino базирана измервателна система, оперираща със следните типове измервателни прибори:

- ✚ Механични;
- ✚ Оптични;
- ✚ Електрически прибори, към които са причислени;
  - ✓ Капацитивни измервателни прибори;
  - ✓ Индуктивни измервателни прибори;
  - ✓ Фотоелектрически измервателни прибори.

Друго изследване се свързва с разработване на microgripper system, позволяваща определяне на два основни параметъра, респективно „позиция“ и „сила“, във връзка с изпитване на различни типове проводници. Системата разполага с компоненти за захващане и освобождаване на тестовите обекти, две групи от „тензорезисторни преобразуватели“, спомагащи отчитането на посочените неелектрически величини. Извършен е анализ на статичните и динамичните характеристики на използваните измервателни технически средства. В изследване е моделиран измервателен преобразувател за сила за целите на механично натоварване на компонентите на симетрични ножове на плугове в областта на селското стопанство. Проведени са целесъобразни процедури във връзка с адекватно позициониране на техническите измервателни средства и подобряване на сензорните характеристики като „чувствителност“, линейност“, „минимизация на грешката“, „разширяване на измервателния обхват“ и „по-ефективно отчитане на спектъра на натоварване“.

Обект на изследване във връзка с измерване на сила и прилагане на измервателни прибори за сила/опън/натиск могат да бъдат не само стационарни метални обекти и съоръжения, но и съвсем различни среди като например „взаимодействието флуид-преграда в отворени водни канали“. Относно събирането на сензорни данни е използван набор от шест технически елементи, подложени на маханично огъване между две позиционни точки. В разглежданата система е налице приложение на апарата на регресионния анализ за определяне на взаимовръзката между захванващи и инструментални сигнали. Описаният подход може да бъде използван за процедури по сензорно калибриране. В друго проучване е засегната задачата за анализ на механичните свойства на полимерни материали и техните характеристики за оценка на приложената сила по изискван критерий за гъвкавост. Механичните свойства на тестовите материали - полиетилен с висока плътност,

фенолформалдеhid и естествен каучук, са тествани при оказване на силови деформации в границите от 1 до 20 N с помощта на измервателни прибори за сила.

Въздействието на сили с различни големина върху детайли и конструкции може да бъде регистрирано с приложение на широк набор от преобразуватели. Разработват се системни решения с комбирано използване на няколко типа технически средства за измерване между съпротивителни, индуктивни, капацитивни, пиезоелектрически, електромагнитни, електродинамични, магнитоеластични, галваномангнитни, вибрационни, акустични, жирокопни и т.н.. Едни от най-често използваните сензорни типове са тензорезисторите. Тензорезисторните преобразуватели се разделят на метални и полупроводникови. Сравняват се по различни критерии като измервателен обхват, чувствителност, съпротивление, толеранс на съпротивлението и размери. Основно се свързват в постояннотокови мостови измервателни схеми в различни конфигурации с един работен, два работни в съседни рамена, два работни в срещуположни рамена и четири работни преобразувателя.

Научните изследвания разглеждат различни системни решения при измерване на сили. Широко разпространени са автоматизирани безжични мрежови системи за мониторинг, свързани с измерване на интензивни еластични повърхностни деформации в обслужвани метални тръбопроводи с пластмасово покритие. В изследване е проектирана многоканална измервателна система за оценка сензорни елементи за деформация на база на USB комуникационен интерфейс. Тестовите модули са снабдени с 8-битов микроконтролер, усилвател с регулируем коефициент на усилване, Бесел нискочестотен филтър и аналогово-цифров преобразувател, управлявани чрез SPI и други контролни сигнали.

### **1.8. Приложения на апарати за прогнозен анализ в информационно-комуникационните системи в задачи за прогнозен анализ**

Според научните изследвания прогнозният анализ на основата на изкуствения интелект в сферата на комуникациите засяга две основни направления:

- ✚ *Направление №1:* намаляващия приток от потребители на услуги в мобилната телекомуникационна индустрия поради възникнали прекъсвания или непредвидени събития в мобилните и клетъчни комуникации;
- ✚ *Направление №2:* цялостния трафик от постъпили потребителски заявки в обслужвани в телекомуникационните и LTE мрежи.

Основните математически инструменти, използвани за количествено прогнозиране по отношение дефинираните целеви направления могат да бъдат разделени в три основни категории (фиг. 1.21), респективно:

- ✚ Машинно обучение;
- ✚ Приложна статистика;
- ✚ Изкуствени невронни мрежи.

### **1.9. Изкуствени невронни мрежи при обработка и редуциране на шумове въздействия в информационно-комуникационните системи**

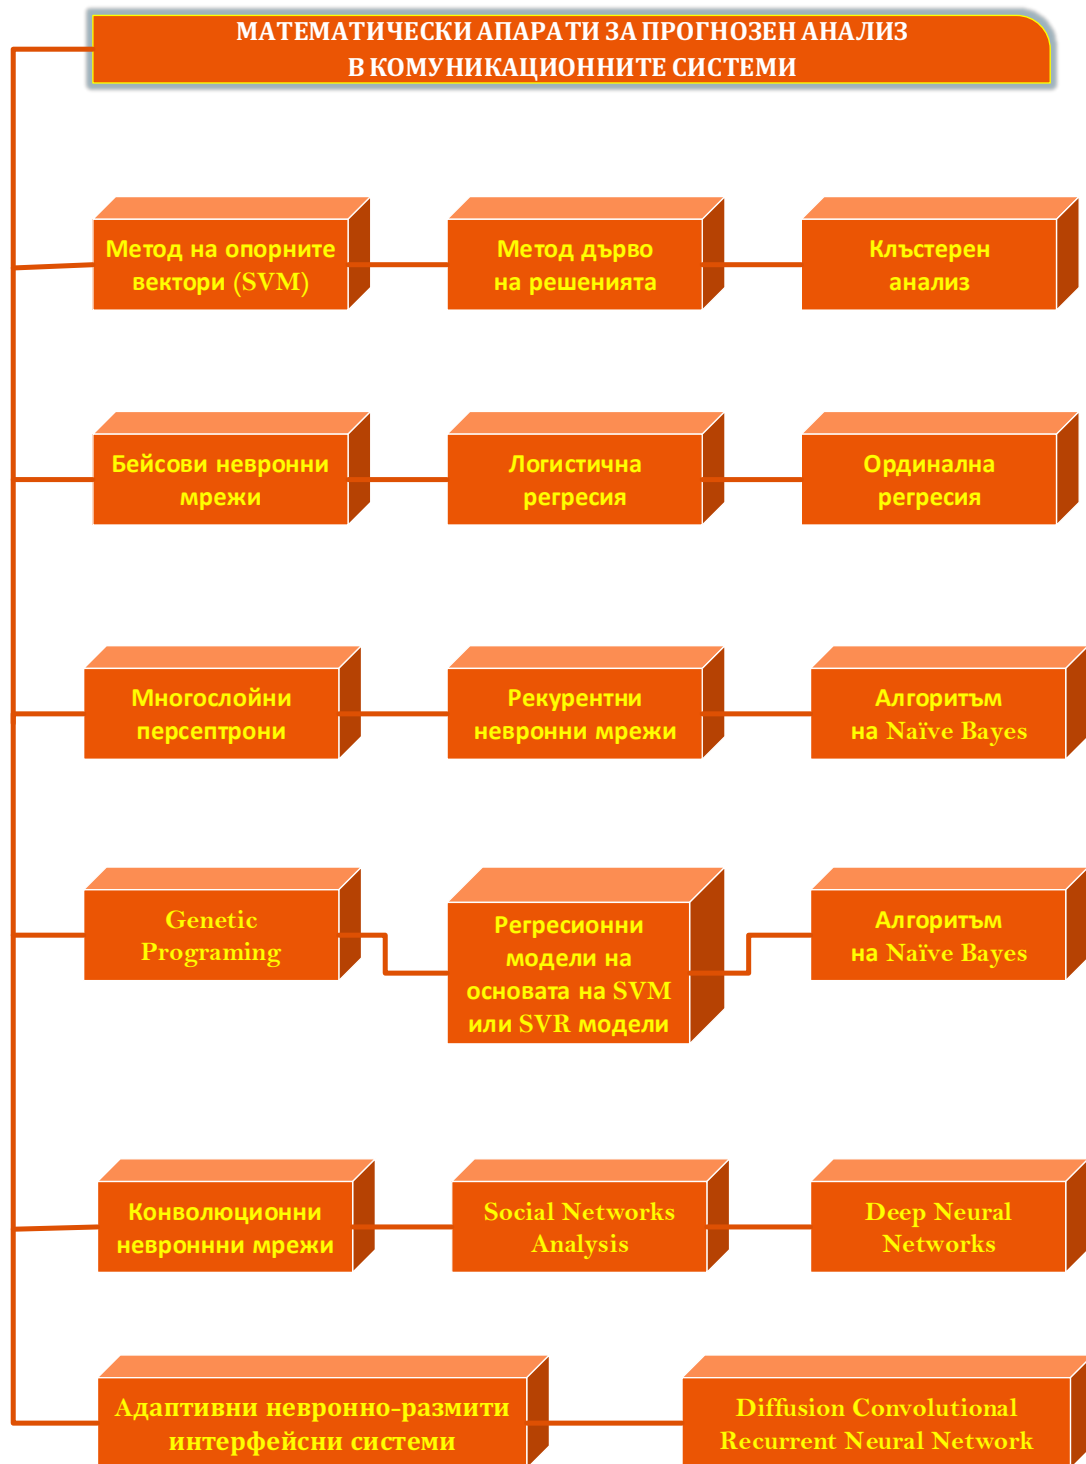
Изследванията по отношение на обработката и анализа на сигнали в информационно-комуникационните системи в различни сфери на индустрията основно са свързани с разпознаване на следните обекти:

- ✚ Речеви сигнали;
- ✚ Звукови сигнали;
- ✚ Биомедицински сигнали,

в канали, представляващи преносна среда с наличие на шумове. Инструменти, които са прилагат за идентификация, са:

- ✚ Дълбоки невронни мрежи - Deep Neural Networks (DNNs);
- ✚ Скрити модели на Марков;
- ✚ Multivariate Analysis of Variance (MANOVA);

✚ Multi-layer Perceptrons и др.



*Фиг. 1.21. Апарати за прогнозен анализ в комуникациите*

Според други проучвания, касаещи процесите по оценяване и редуциране на шумове, е налице приложимост на специализирани подходи и алгоритми, между които могат да бъдат посочени, респективно:

- ✚ Independent Component Analysis, Рекурсивна версия на метода на най-малките квадрати - Recursive Least Squares (RLS), и Recurrent Neural Networks в автоматизирано системите за разпознаване на реч;

- ✚ Метод на опорните вектори - Support Vector Machine (SVM), k-means клъстерен анализ, k – най-близки съседни - k – Nearest Neighbors (k-NN), в оптичните комуникации;
- ✚ DNNs и Convolutional Neural Networks в Orthogonal Frequency-Division Multiplexing (OFDM) и Two-Dimensional Magnetic Recording (TDMR) системи;
- ✚ RNN невронни архитектури в комбинация с Long Short Term memory (LSTM) – разновидност на RNNs, и Gated Recurrent Unit (GRU-GRU) в Micro-Electro-Mechanical System Inertial Measurement Units (MEMS-IMU);
- ✚ Deep-Learning Neural Networks (DLNNs) при разработка на биомедицински електронни устройства;
- ✚ Principal Component Analysis, CNN, Feed-Forward Neural Networks при редукция на параметрите:
  - ✓ Signal-to-Noise Ratio (SNR);
  - ✓ SNR RMS (Root Mean Square) параметрични стойности;
  - ✓ Peak SNR;
  - ✓ Structural Similarity Index Measure (SSIM),
- ✚ в системи за диагностика на изображения;
- ✚ Линеен регресионен анализ, Дискриминантен анализ, алгоритъм на Naïve Bayes, метод Дърво на решенията, Адаптивни невронно-развити интерфейсни системи в електрониката.

#### **Изводи към първа глава**

- ❖ Разгледани са особеностите на основни типове интерфейси и стандарти за пренос на сензорна и параметрична информация при реализация на сензорни модули и многофункционални платки в електрониката и комуникациите;
- ❖ Направена е обща функционална класификация на сензорните елементи, използвани различни области на индустрията и техниката, според възбуждащите фактори и принципа на преобразуване. Дефинирани са основните видове характеристики, които могат да бъдат обект на изследване при изучаване на сензорната функционалност;
- ❖ Съставена е класификация на интелигентните комуникационни приложения и технологии и направен сравнителен анализ между WAN и технологи LAN, както и по отношение на основни IEEE стандарти за пренос на данни;
- ❖ Изучени са основни технически измервателни средства за следене и регистрация на измерванията на силови натоварвания върху метали детайли и конструкции и сензорни системи за измерване на натоварвания в различни сфери на индустрията, както и същността, спецификата и особеностите на апарата на изкуствените невронни мрежи;
- ❖ Дефинирани са областите на приложение на методи, алгоритми и подходи на математическата и приложна статистика, машинното обучение и изкуствения интелект, използвани за прогнозен анализ в телкомуникационните системи по отношение на потребителите на комуникационни услуги и обработвания трафик;
- ❖ Проведен е анализ на методите и техническите подходи за цифрова обработка и филтрация на сигнали и ролята на изкуствения интелект при редуциране на шумове към сигнали в информационно-комуникационните системи от различни области.

## **ГЛАВА II. РАЗПОЗНАВАНЕ НА ШУМОВЕ И СИГНАЛИ С ШУМОВЕ В СИМУЛАЦИОННО МОДЕЛИРАНИ КОМУНИКАЦИОННИ КАНАЛИ ЗА ВРЪЗКА**

### **2.2. Модели за идентификация на шумове на основата на изкуствени невронни мрежи с обучение по обратно разпространение на грешката**

#### **2.2.1. Изследване и синтез на изкуствени невронни мрежи за разпознаване на шумове при Levenberg-Marquardt обучаващ алгоритъм**

Приведено е изследване във връзка с възможността за приложение на апарата на изкуствените невронни мрежи относно някои от най-разпространените типове шум, съпътстващи процеса на

предаване на аналогови и цифрови сигнали в комуникационните канали за връзка. Анализът се прилага по отношение на следните типове шум:

- Gaussian White Noise - GWN;
- Periodic Random Noise – PRN.

За целта е направена симулация на тестовите шумове при фиксирани идентични стойности на стандартното отклонение за GWN и спектралната амплитуда при PRN, съответно 0.02, 0.04 и 0.06, чрез програмния продукт LabVIEW. Следвайки аналогията на посочените нива на симулационните параметри е формирана информационна извадка, в която са включени от 2000 наблюдения с три информативни признака, съответно GWNs - 1000 еталона, и PRNs - 1000 еталона.

Въведен е подход за синтез на архитектури на основата на трислойни архитектури на изкуствени невронно мрежи с пряко разпространение на сигналите и обратно разпространение на грешката. Относно целите на изследването се предвиждат процедури с приложение на Levenberg-Marquardt алгоритъм при експериментиране с обучаващите параметри (goal, learning rate, min\_grad и т.н.) при последователно нарастване на невроните в междинния (скрития) слой в границите от 5 до 20 единици. Обучението и селекцията на изкуствени невронни мрежи за разпознаване на GWNs и PRNs се свързва още със задаване на различни типове на активация на изхода, т.е. използване на:

- линейна – purelin тип;
- тангенс-сигмоидална – tansig тип;
- логаритмична-сигмоидална функция на активация – logsig тип.

При линейна активация са регистрирани минимална 98.3% и максимална 100.0 % точност при 5 и 15 междинни неврона. Грешката варира от 0.0118 при 15 до 0.0441 при 5 скрити неврона. По отношение на тангенс-сигмоидална изходна активация е наблюдавана най-ниска точност 98.3 % при 10 и 20 скрити невронни единици, докато най-високата 100.0 % е достигната при 8 и 13. При втория критерий за качество е констатирано изменение от 0.0021 до 0.0140, съответно при 13 и 19 неврона в междинния слой. Във връзка с последния приложен тип на активация на изхода се наблюдават ниски и високи точности с приблизителна разлика около 50 %, като преобладаващи са вторите нива. Също така е установено ясно изразено значително повишаване в пъти на средноквадратичната грешка в рамките на целия изследван диапазон от скрити невронни единици в сравнение с тези при tansig и purelin тип. Регистрирани са минимална 47.7 % и максимална точност 100 % при 8 и 10 скрити неврона, за които са постигнати  $MSE = 0.2500$  и  $MSE = 0.1255$ .

**Таблица 2.1.** Резултати при разпознаване на GWNs и PRNs с изкуствени невронни мрежи с линейна изходна активационна функция

Скрити неврони	Точност, %	Средноквадратична грешка
5	94.0	0.0441
6	97.0	0.0310
7	97.7	0.0255
8	97.3	0.0284
9	98.3	0.0224
10	97.3	0.0282
11	99.7	0.0201
12	98.0	0.0265
13	97.3	0.0256
14	98.3	0.0251
15	100.00	0.0118
16	99.7	0.0188
17	98.3	0.0235
18	99.3	0.0170
19	99.0	0.0173
20	98.7	0.0219




**Таблица 2.2.** Резултати при разпознаване на GWNs и PRNs групи сигнали с изкуствени невронни мрежи с тангес-сигмоидална изходна активационна функция



Скрити неврони	Точност, %	Средноквадратична грешка
5	99.3	0.0078
6	99.3	0.0115
7	99.0	0.0065
8	100.0	0.0074
9	98.7	0.0102
10	98.3	0.0115
11	99.3	0.0107
12	98.7	0.0121
13	100.00	0.0021
14	98.7	0.0126
15	99.3	0.0069
16	99.7	0.0091
17	99.7	0.0069
18	98.7	0.0140
19	99.7	0.0130
20	98.3	0.0137

**Таблица 2.3.** Резултати при разпознаване на GWNs и PRNs групи сигнали с изкуствени невронни мрежи с логаритмична-сигмоидална изходна активационна функция

Скрити неврони	Точност, %	Средноквадратична грешка
5	94.3	0.1498
6	98.0	0.1357
7	98.7	0.1904
8	47.7	0.2500
9	99.3	0.1276
10	100.00	0.1255
11	48.3	0.2500
12	56.0	0.1807
13	99.3	0.1289
14	49.3	0.1904
15	99.7	0.1268
16	99.3	0.1281
17	99.7	0.1262
18	52.0	0.1864
19	99.7	0.1255
20	99.7	0.1276



a)



**Фиг. 2.4.** Избрани невронни мрежи за разпознаване на GWNs и PRNs при изходна а) линейна, б) тангес-сигмоидална и в) логаритмична-сигмоидална активационна функция

Откроява се тенденция на преимущество на тангес-сигмоидалната пред линейната и най-вече спрямо логаритмична-сигмоидална активационна функция предвид получените по-ниски стойности на критерия „средноквадратична грешка“. На фиг. 2.4 са представени експериментално селектираните мрежи с 15, 13 и 10 междинни неврона с най-добри показатели.

### 2.3. Модели за разпознаване на цифрови сигнали с наличие на шумове чрез изкуствени невронни мрежи с обучение по обратно разпространение на грешката

#### 2.3.1. Изследване и синтез на изкуствени невронни мрежи за идентификация на шумове към цифрови сигнали

На следващ етап от анализа са симулирани правоъгълни сигнали с наличие GWN и PRN при нива на конфигурационните параметри 0.02, 0.04 и 0.06. Тук е приложен аналогичен подход по отношение на оценка на качеството на класификация и дейностите по селекция на невронни мрежи за идентификация. Резултатите от изследването са изложени от таблица 2.4 до таблица 2.6.

Съгласно приложението на линейна функция на активация в изхода на невронните мрежи са получени високи вариации на точността, изменяща се от 93.3 % до 100.0 % за 6 и 16 невронни изчислителни единици. Стойностите на средноквадратичната грешка не падат под ниво от 0.0150 като са наблюдавани най-малка  $MSE = 0.0155$  и най-голяма  $MSE = 0.0747$ , съответно при фиксирани 16 и 6 неврона в структурните скрити слоеве на изследваните мрежи.

**Таблица 2.4.** Резултати при разпознаване на правоъгълни сигнали с GWN и PRN с изкуствени невронни мрежи с линейна изходна активационна функция

Скрити неврони	Точност, %	Средноквадратична грешка
5	96.0	0.0355
6	93.3	0.0747
7	97.0	0.0511
8	95.7	0.0396
9	98.7	0.0294
10	98.7	0.0227
11	98.7	0.0264
12	98.0	0.0352
13	99.3	0.0191
14	98.7	0.0240
15	99.0	0.0234

16	100.00	0.0155
17	97.3	0.0332
18	99.7	0.0160
19	96.3	0.0273
20	99.0	0.0241

В хода на експеримента при  $\text{tansig}$  изходен активационен тип е констатирано минимално показание за точността 91.7 % при 5 скрити неврона, като за останалата по-голяма част от тестовия интервал критерия се изменя от 97.7 % при 12 до най-високата си стойност 100.0% при 17 неврона. Нивата на MSE варират от 0.0186 до 0.0049 при 12 и 17 неврона в скрития слой с изключение на регистрираната  $\text{MSE} = 0.0608$  при 5 междинни неврона.

**Таблица 2.5.** Резултати при разпознаване на правоъгълни сигнали с GWN и PRN с изкуствени невронни мрежи с тангес-сигмоидална изходна активационна функция

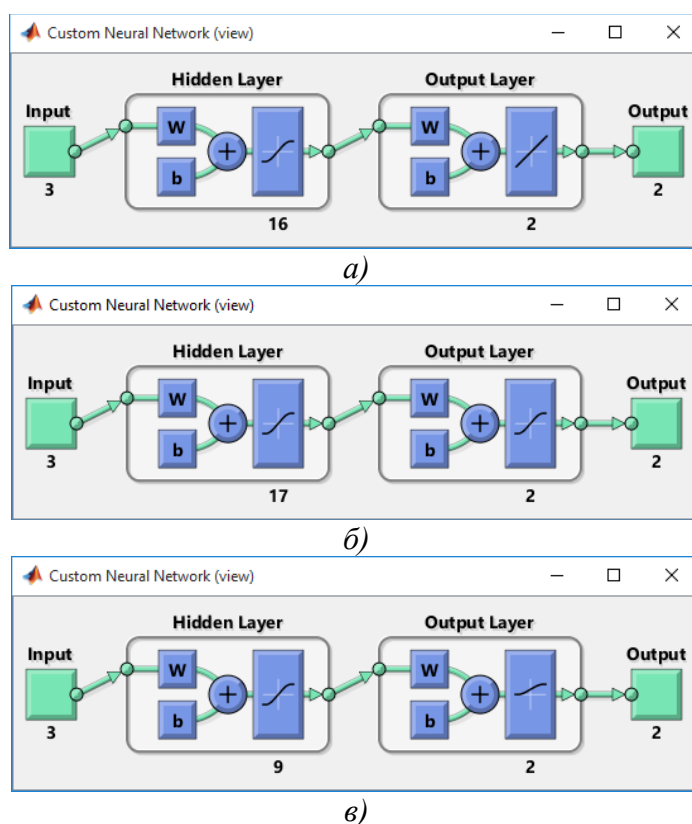
Скрити неврони	Точност, %	Средноквадратична грешка
5	91.7	0.0608
6	99.0	0.0076
7	99.3	0.0072
8	99.00	0.0084
9	98.3	0.0142
10	98.0	0.0162
11	99.3	0.0063
12	97.7	0.0186
13	98.3	0.0158
14	98.3	0.0144
15	99.0	0.0117
16	99.7	0.0057
17	100.0	0.0049
18	99.7	0.0171
19	99.0	0.0136
20	98.7	0.0159

**Таблица 2.6.** Резултати при разпознаване на правоъгълни сигнали с GWN и PRN с изкуствени невронни мрежи с логаритмична-сигмоидална изходна активационна функция

Скрити неврони	Точност, %	Средноквадратична грешка
5	95.7	0.1427
6	89.0	0.1917
7	95.3	0.1445
8	83.7	0.1960
9	100.0	0.1260
10	98.3	0.1330
11	60.0	0.2009
12	76.7	0.1603
13	70.7	0.1963
14	99.0	0.1285
15	98.7	0.1284
16	52.3	0.1868

17	49.3	0.1889
18	74.3	0.1612
19	99.0	0.1282
20	57.3	0.1831

Анализирайки резултатите, съдържащи се в таблица 2.6, се забелязва подобна тенденция за силно завишени степени на средноквадратичната грешка в сравнение с *purelin* и *tansig* в указания ход на изменение на скритите неврони, установена в предходната част от изследванията, насочени единствено към анализ на шумове в имитирана комуникационна среда. Тук също се наблюдават влошени точности за конкретни междинни неврони, въпреки че няма така ясно разграничени групи на „ниски“ и „високи“ вариации на показателя със значителна разлика, т.е. има наличие на междинни нива – например 60 % при 11; 70.7 при 13; 76.7 при 12; 83.7 при 8 междинни неврона и т.н. Налице е обратнопропорционална връзка между намаляването на точността от 100.0 % до 70.7 % при увеличаване на изчислителните неврони за ограничена част от техния диапазон - от 9 до 13. Най-ниска степен на критерия за качество 49.3 % е регистрирана при архитектура със седемнадесет междинни неврона. MSE се изменя от 0.1260 за случая на най-висока точност до 0.2009 при 11 неврона в скрития мрежови слой.



**Фиг. 2.14.** Избрани невронни мрежи с а) линейна, б) тангес-сигмоидална и в) логаритмична-сигмоидална изходна активационна функция за разпознаване на правоъгълни сигнали с *GWN* и *PRN*

Намерени са архитектури на мрежи с 16, 17 и 9 междинни структурни неврони, отговарящи на необходимост за поддържане на оптималност между очаквана висока точност при същевременна регистрация на минимално MSE показание, дадени на фиг. 2.14.

## 2.4. Изследване и подбор на FFNN невронни архитектури за идентификация на шумови въздействия и цифрови сигнали с добавени шумове на основата на Scaled Conjugate Gradient обучение

### 2.4.1. Синтез на невронни мрежи с право разпространение на сигналите и обратно разпространение на грешката при SCG алгоритъм за разпознаване на имитирани *GWN* и *PRN* смущаващи въздействия в комуникационни канали за връзка

Друга потенциална възможност за невронен синтез се свързва с промяна на обучаващия алгоритъм и типа на изходната активационна функция като:


- ✚ Levenberg-Marquardt се замени с Scaled Conjugate Gradient обучаващ алгоритъм;
- ✚ Softmax тип активация бъде зададен в структурните изходни неврони.

Спецификата на въведените параметри, произтичаща от използване на softmax функция на активация, определя изходните резултати от приложение на невронния апарат да бъдат приемани като „вероятност“, а не като „числова интерпретация“.


**Таблица 2.7.** Резултати от селекция на FFNNs при SCG обучение за идентификация на GWN и PRN

<i>Скрити невронни единици</i>	<i>Точност, %</i>	<i>Cross-Entropy индикатор</i>
3	92.8	2.46521e-0
5	99.0	4.29463e-0
7	99.7	4.84113e-0
9	99.7	4.59377e-0
11	99.8	6.07409e-0
13	99.8	6.76620e-0
15	99.8	6.12029e-0
17	97.2	1.97068e-0
19	99.2	3.74847e-0
21	99.8	6.06058e-0
23	99.2	4.04383e-0
<b>25</b>	<b>99.8</b>	<b>5.58345e-0</b>
27	99.8	5.77250e-0
29	99.7	6.64407e-0
31	99.2	4.01312e-0
33	99.8	6.61422e-0


Таблица 2.7 съдържа получените резултати в хода на изследване на FFNNs при използване на SCG за разпознаване на случайни шумови въздействия – GWN и PRN, при заложено изменение на изчислителните структурни звена в скритите слоеве от 3 до 31. Критерии, подложени на оценка, са „точността“ и „Cross-Entropy“ от разпознаване. Относно анализирания интервал от междинни неврони са установени удовлетворяващи нива на точност над „0.99“. Най-ниската констатирана точност се равнява на 92.8 % при базова архитектура на изследване, докато най-висока стойност на критерия 99.8 % е регистрирана за случаите на 11, 13, 15, 21, 25, 27 и 33 неврона в междинния слой на FFNNs. В този случай изборът на краен вид модел за идентификация се основава на достигнатата минимална ентропия „5.58345e-0“ за архитектура с 25 скрити неврона, показана на фиг. 2.24.



**Фиг. 2.24.** Селектирана FFNN невронна архитектура в хода на SCG обучение за идентификация на GWN и PRN въздействия



**Фиг. 2.25.** Cross-Entropy при синтезираната FFNN невронна архитектура в хода на SCG обучение за идентификация на GWN и PRN въздействия



**Фиг. 2.26.** Диаграма на грешките за избраната FFNN невронна архитектура в хода на SCG обучение за идентификация на GWN и PRN въздействия

Тенденцията на подобно и постепенно намаляващо изменение на SE индикатора от обучение, валидиране и тестване на фиг. 2.25 свидетелства за коректността на приложените процеси. Цялостният обучаващ процес обхваща 103 итерации като „най-добрата валидираща производителност“ е намерена при 97-ми обучаващ цикъл.

Показана е хистограма на мрежовите грешки на фиг. 2.26, за която се наблюдава близко разположение на индикациите от основните мрежови процеси относно данните от тестовата извадка до нивото на базисната нулева грешка. Според представената зависимост грешките от приложение на модела попадат в обхвата на нива „-0.04966“ и „0.04966“.


#### 2.4.2. Селекция на FFNNs при SCG алгоритъм за идентификация на имитирани цифрови сигнали с насложени GWN и PRN случайни въздействия в комуникационни канали за връзка

Предвид положителните индикации от адаптиране на SCG обучение при анализ на имитирани смущаващи въздействия на средата в комуникационни канали за връзка беше преминало към задачата за разпознаване на шумове, които са насложени към предавани цифрови сигнали. По отношение на


това в таблица 2.8 са обобщени данни за точността и SE критерия за еднакъв с предходното изследване диапазон от скрити неврони. Относно архитектура при 3 изчислителни единици беше наблюдавана минимална точност 69.3 % и  $CE = 1.27713e-0$ . В хода на обучение на FFNNs с нарастване на невроните в междинния слой бяха констатирани приблизителни нива на точност „91.0 %“, „94.0 %“, „96.0 % до 98.8 %“, максималното, от които се отнася за архитектура с 31 скрити неврона и  $CE = 3.86609e-0$ .

**Таблица 2.8.** Резултати от изследване на FFNNs при SCG обучение за разпознаване на цифрови сигнали с присъствие на GWN и PRN


Скрити невронни единици	Точност, %	Cross-Entropy индикатор
3	69.3	1.27713e-0
5	98.2	3.11645e-0
7	97.4	2.69296e-0
9	91.6	2.21454e-0
11	93.9	1.35195e-0
13	98.7	5.49103e-0
15	97.0	2.46378e-0
17	97.8	2.37423e-0
19	96.7	1.84056e-0
21	97.2	2.20736e-0
23	98.6	3.33221e-0
25	99.3	5.61578e-0
27	97.8	2.85755e-0
29	97.9	2.70141e-0
<b>31</b>	<b>98.8</b>	<b>3.86609e-0</b>
33	98.3	3.30483e-0



**Фиг. 2.27.** Синтезирана FFNN невронна архитектура при SCG обучаващ алгоритъм за разпознаване на цифрови сигнали с присъствие на GWN и PRN



**Фиг. 2.28.** Cross-Entropy за селектираната FFNN невронна архитектура при SCG обучаващ алгоритъм за разпознаване на цифрови сигнали с присъствие на GWN и PRN



**Фиг. 2.29.** Диаграма на грешките за избраната FFNN невронна архитектура при SCG обучаващ алгоритъм за разпознаване на цифрови сигнали с присъствие на GWN и PRN

Синтезираният най-добър модел за идентификация на правоъгълни сигнали с влияние на Гаусов и Периодичен шум е показан на фиг. 2.27. Във връзка с модела е използвано процентно съотношение 70:15:15 % между данните от входния набор, разделени на случаен принцип. Фигура 2.28 отразява поведението на мрежата при протичане на обучаващите, валидиращите и тестовите процедури. Наблюдавано е подобно и низходящо изменение на SE, определящо се като отсъствие на индикация за невронно преобучение. В границите на 111 от общ брой от 117 цикъла на обучение е достигната най-добра мрежова производителност 0.027901.

Оцененият вариационен диапазон на грешките, наблюдаван непосредствено до нивото на нулевата грешка на фиг. 2.29, от интегриране на модела за целите на разглежданата задача е  $\pm 0.04915$ . Относно опериране с минимална част от обучаващите данни очакваните грешките попадат на степен  $\pm 0.1474$ .

#### Изводи към втора глава

- ❖ Изготвен е подход за изследване и селекция на изкуствени невронни мрежи с пряко разпространение на сигналите чрез Levenberg-Marquardt (LM) и Scaled Conjugate Gradient (SCG) обучение на основата на градиентен алгоритъм със залагане на обратно разпространение на грешката за разпознаване на шумове и сигнали с наличие на шум при регулация на функциите на активация при анализ на точността, средноквадратичната грешка, индикатора cross-entropy, значимостта на корелация и обобщените прогнозни резултати;
- ❖ Установени са положителни и отрицателни аспекти, както и идентични тенденции по отношение на индикаторите за качество от приложението на линейна, тангенс-сигмоидална и логаритмична-сигмоидална активационна функция в изходните слоеве при направения подбор на изкуствени невронни мрежи при LM обучение, определящи най-ниска степен на пригодност последния тип функция, въпреки постигнатите положителните индикации по отношение на точност и корелация;
- ❖ Синтезирани и анализирани са архитектури на основата на изкуствен интелект и LM обучаващ алгоритъм за идентификация на имитирани шумове в комуникационни канали за връзка при линейна, тангенс-сигмоидална и логаритмична-сигмоидална функция на изхода с явно преимущество на тангенс-сигмоидалния тип на активация;
- ❖ Селектирани и оценени са структури на изкуствени невронни мрежи при LM обучение за разпознаване и класификация на симулационно получени цифрови сигнали с добавени въздействия на Гаусов постоянен шум и Периодичен случаен шум



според приети критерии за качество на базата на експериментални изследвания според различно заявени неврони в скритите слоеве и подбор на тип на функция на активация с констатирана най-добра адекватност на на тангенс-сигмоидалния тип;

- ❖ Създадени и оценени са FFNN невронни модели в хода на SCG обучаващ алгоритъм за идентификация на имитирани индивидуални и комплексни към цифрови сигнали случайни Гаусови и Периодични въздействия при информационно предаване в комуникационни канали за връзка.

## ГЛАВА III. МОДЕЛИ ЗА КАЧЕСТВЕН И КОЛИЧЕСТВЕН АНАЛИЗ НА ИНФОРМАЦИЯ ОТ ТЕНЗОРЕЗИСТОРНИ ПРЕОБРАЗОВАТЕЛИ

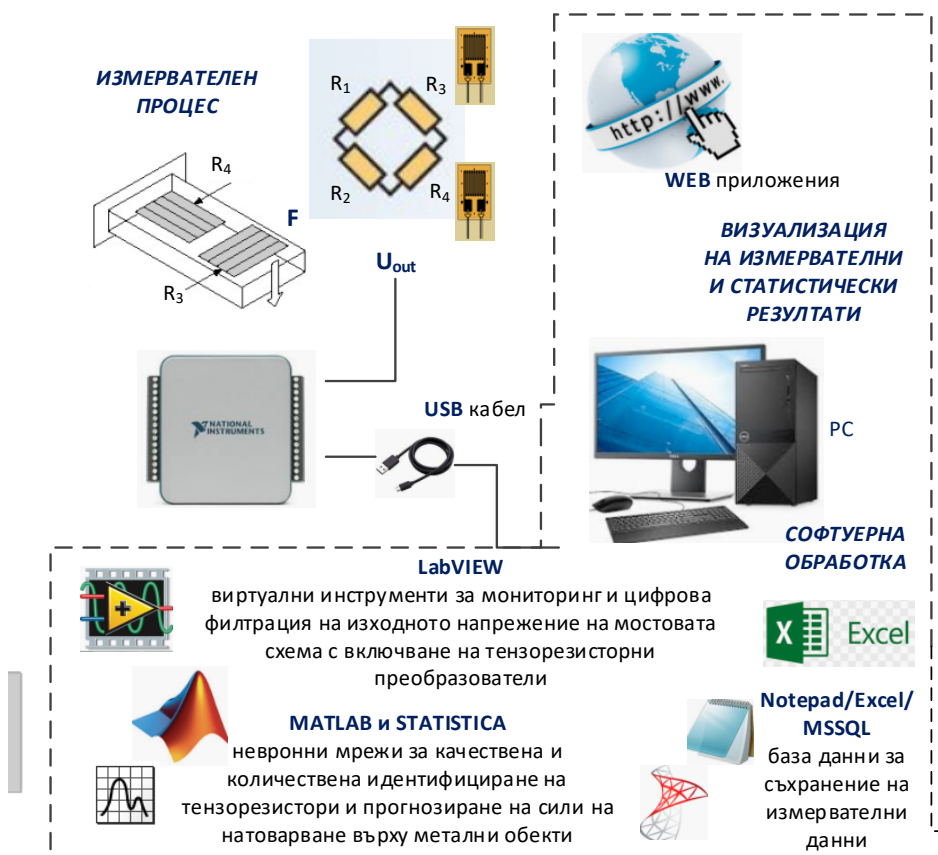
### 3.1. Система за изследване на натоварване на метални обекти под въздействие на сили на основата на тензорезисторни преобразуватели

Направление, което представлява интерес за практиката в:

- областта на комуникациите;
- сензорните системи за събиране и анализ на данни във връзка с електрически и неелектрически величини;
- автоматизираните информационни системи за следене на технологични обекти и процеси в сферата на индустрията,

е възможността за адаптиране на указаните математически инструменти по направления за качествен и количествен анализ на информация, регистрирана посредством тензорезисторни преобразуватели, при силово натоварване на различни метални обекти.

Във връзка с това е предложена концепция на комуникационна система за изследване и анализ на степен на натоварване на детайли под въздействие от сили с различна големина, чиято блокова архитектура е показана на фиг. 3.1.



Фиг. 3.1. Архитектура на система за анализ на сили върху метални обекти посредством тензорезисторни преобразуватели

Тестови експериментален обект на изследването е метална конзолна гредка, върху която се прилагат сили в перпендикулярно направление. Върху повърхността са залепени два тензорезисторни преобразуватели, разположени така, че да осигури необходимата температурна компенсация без необходимост от допълнителен сензорен елемент. Тензорезисторните преобразуватели се свързват в съседни рамена на стандартен мост за постоянен ток. В резултат от натоварването на гредата се изменят електрическите и механични параметри на сензорите, както и напрежението в измервателния диагонал на моста, чиято големина се измерва посредством модул на модул NI 6002 на фирмата National Instruments. Чрез LabVIEW виртуални приложения изходното напрежение на моста се следи, използвайки конфигуриран сериен комуникационен канал между NI 6002 и персонален компютър, и филтрира в реално време чрез цифрови рекурсивни (IRR) и нерекурсивни (FIR) звена.

Предвидена е възможност се статистически анализ на регистрираните данни по отношение на различни показатели като минимална, средна и максимална стойности, стандартно отклонение, времена на максимума и минимума и други. На база на експериментално изведени математически регресионни модели с пакет STATISTICA, зададени в LabVIEW чрез специфициран подвиртуален инструмент, се калкулират прогнозни стойности на въздействащата сила в случаите при един или два използвани тензорезистора.

Посредством MATLAB скриптове в LabVIEW се извикват и зареждат параметрите на предварително обучени изкуствени невронни структури:

- при пряко разпространение на сигналите и обратно разпространение на грешката;
- обобщени регресионни невронни мрежи,

за идентификация на включените работни сензорни елементи в мостовата схема, използвани в момента при измерване на входната неелектрическа величина – качествен анализ на данни от тензорезисторни сензори. Тук непосредствено се включват и невронни модели за прогнозиране на натоварването от приложените сили върху тестовия метален обект, т.е. налице е задача за количествен анализ на данни от тензорезисторни сензори.

Използвайки наличието на WEB сървър към виртуална среда LabVIEW се реализира възможността за отдалечен достъп до инструментите за:

- установяване и конфигурация на връзката с USB модула, както и следене на състоянието на някои от неговите аналогови входове. В конкретния случай това е напрежението в измервателния диагонал на мостовата схема с включване на тензорезисторни преобразуватели;
- обработка и визуализация на измервателни и статистически резултати, както и такива от качествен и количествен анализ през Интернет среда.

Изборът на основния невронен апарат с право разпространение на сигналите и обратно разпространение на грешката (FFNNs) е направен съобразно главното предимство за минимизация на грешката след хода на всяка обучаваща итерация относно приложения градиентен алгоритъм.

### **3.2. Виртуални инструменти за филтриране и дескриптивен анализ на измервателни данни от работни тензорезистивни преобразуватели при изследване на силови натоварвания върху метални обекти**

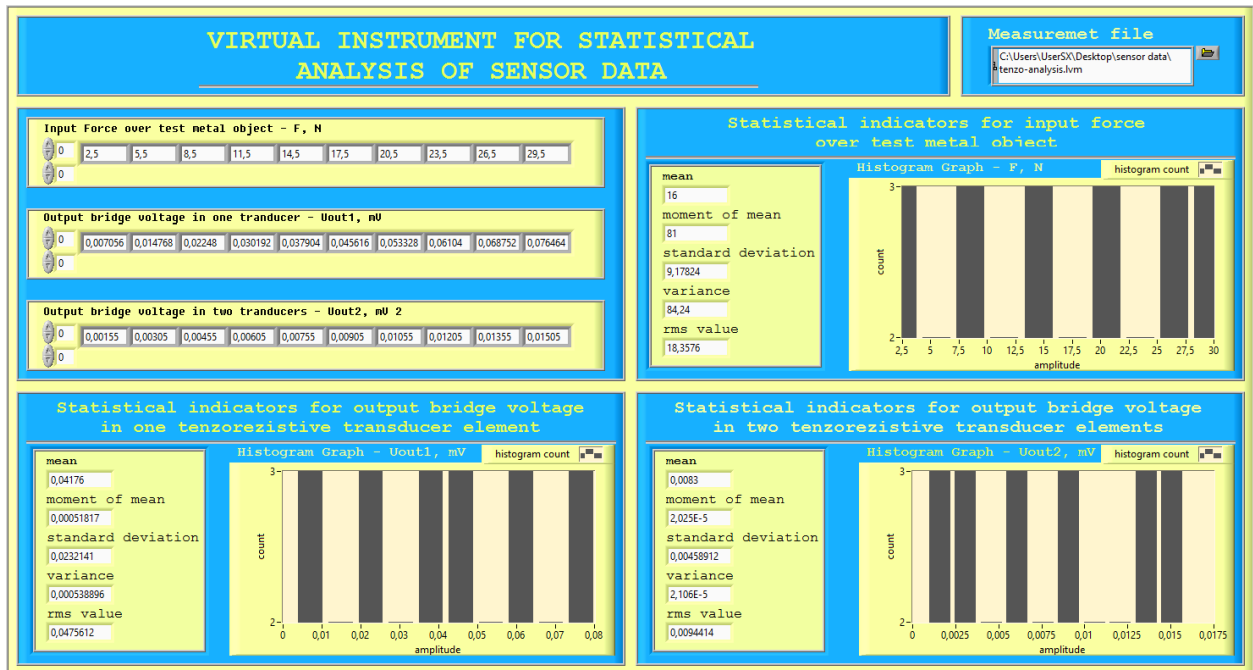
Във връзка с допълнителен дескриптивен анализ на регистрираните силови въздействия, приложени върху експериментални метални обекти, и пропорционални нива на напрежението в измервателния диагонал на мостовата схема с включване на тензорезисторни преобразуватели е създадено спомагателен виртуален инструмент. Потребителският интерфейс и блоковата диаграма на приложението са представени на фиг. 3.4.

Изборът на опитни данни с разширение „.lvm“ за последващ анализ се извършва чрез предвиден контролен елемент, чиято коректност на запис може предварително да бъде проверена чрез Notepad и MS Excel среди. Цифрови индикатори на масиви от данни са предназначени за извеждане на:

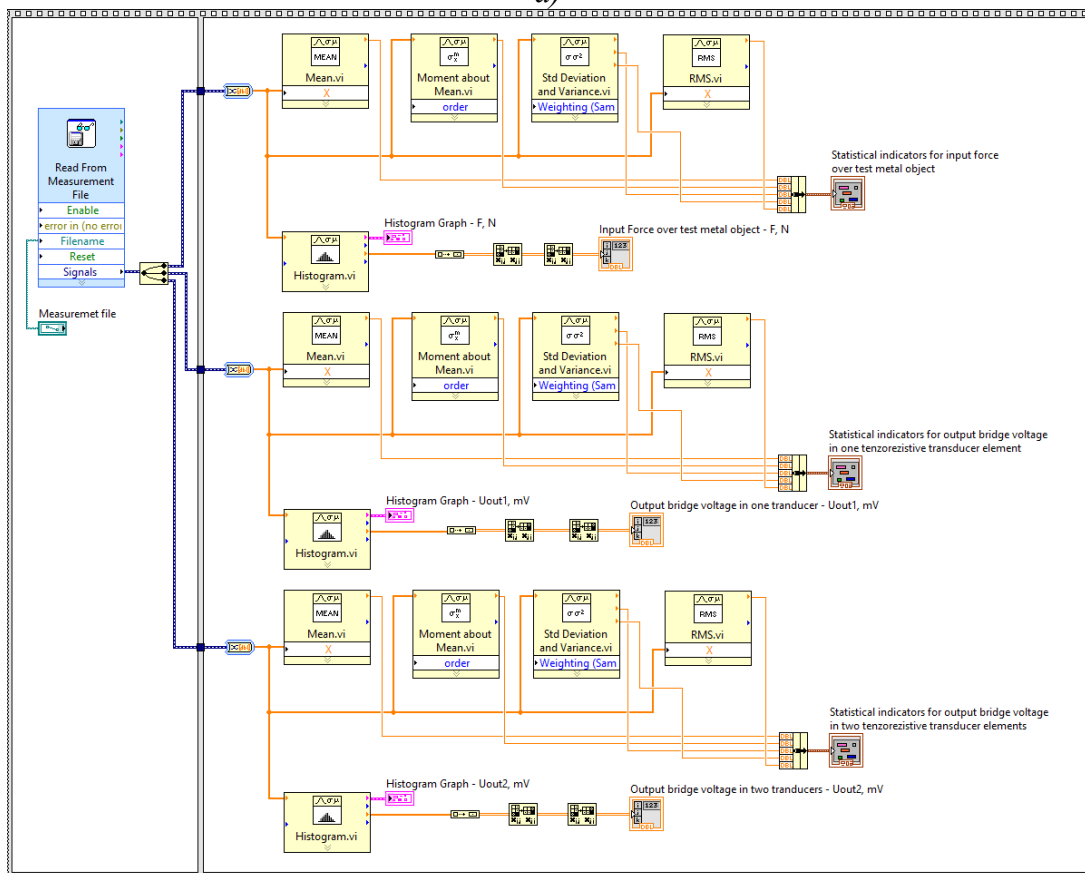
- ❖ приложената сила на натоварване  $F, N$ ;
- ❖ отчетеното измервателно напрежение като реакция на един чувствителен елемент  $U_{out1}, mV$ ;

❖ измереното напрежение на мостовата схема при включване на два работни преобразувателя  $U_{out2}$ , mV.

Относно указаните параметри на мониторинг са въведени функционални хистограми, даващи информация за нивата на техни изменение в хода на експерименталните процедури, които могат да бъдат допълнително анализирани и оценени.



a)



б)

Фиг. 3.4. Виртуално приложение за статистически анализ на регистрирани сензорни данни при натоварване на метални обекти

Основната роля на виртуалното приложение касае използване на специфицирани подвиртуални инструменти за извличане на зададени статистически показатели, идентични за трите изследвани величини. Анализът обхваща следните параметри:

- ❖ Средна стойност;
- ❖ Текущ момент на регистрация на средна стойност;
- ❖ Стандартно отклонение;
- ❖ Вариация;
- ❖ RMS стойност.

### 3.5. Синтез на изкуствени невронни мрежи за идентификация на работни преобразуватели при анализ на сили върху метали в мостова схема на включване чрез FFNNs при SCG обучение

Извършено е обучение на трислойни FFNNs невронни архитектури за количествена идентификация на включени работни измервателни тензорестивни преобразуватели при следене на натоварването върху метални обекти. Архитектурите са изградени на основата на:

- ❖ входен невронен слой;
- ❖ скрит или още наречен междинен слой при залагане на невронни изчислителни звена с тангенс-сигмоидална активация;
- ❖ изходен слой при задаване на softmax функция на активация.

Обучаващите процеси са базирани на Scaled Conjugate Gradient алгоритъм при подаване на една и две входни променливи, съответно:

- ❖ “Uout” – изходното напрежение в индикаторния диагонал на мостова схема за включване на сензорни елементи;
- ❖ “F и Uout” – комбинация от приложена сила върху върху опитен образец и респективно отчетено изходното напрежение на мостова схема.

Дефинирани са следните изходни класификационни групи:

- ❖ Клас №1: Мостова схема с един работен тездоресисторен чувствителен елемент;
- ❖ Клас №2: Мостова схема с два работни тездоресисторен преобразувателя,

където за кодиране на всяка изходна група са използвани комбинации от вероятности при съответни нива – „1 0“ за клас №1 и „0 1“ при клас №2.

Извършена е оценка на изкуствени невронни мрежи след обучение според постигнатите степени индикаторите:

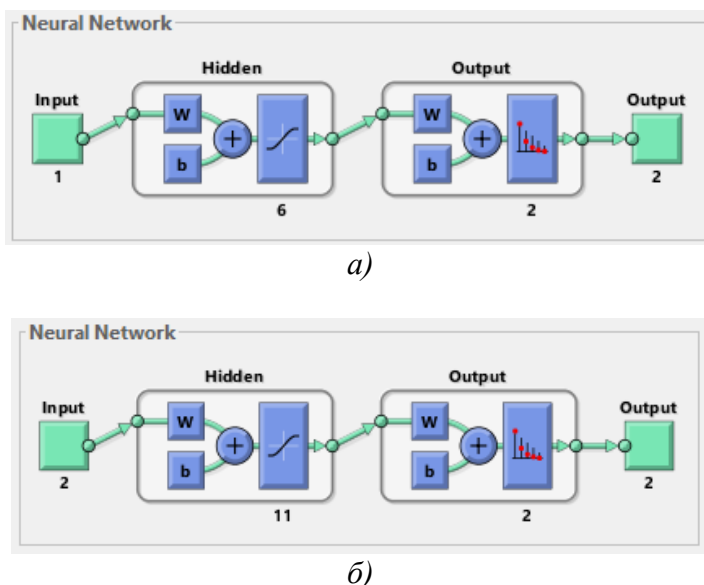
- ❖ “Класификационна точност“;
- ❖ “Cross-Entropy”

**Таблица 3.1.** Изследване на FFNN архитектури при една и две входни променливи при SCG обучение

Скрити неврони	Точност, %	Cross-Entropy	Точност, %	Cross-Entropy
5	90.40	1.48916e-0	100.00	4.29507e-0
6	<b>90.40</b>	<b>1.10373e-0</b>	100.00	13.56822e-0
7	88.50	1.04975e-0	98.10	1.96157e-0
8	90.40	1.61987e-0	100.00	13.84607e-0
9	90.40	1.25043e-0	100.00	14.58822e-0
10	90.40	1.54694e-0	98.10	2.77515e-0
11	90.40	1.55780e-0	<b>100.00</b>	<b>2.94522e-0</b>
12	90.40	1.22658e-0	100.00	13.14914e-0
13	90.40	2.240027e-0	100.00	3.16867e-0
14	90.40	3.11792e-0	100.00	14.30631e-0
15	90.40	3.19195e-0	100.00	3.39250e-0

Във връзка с дефинираните класификационни групи посочените индикатори са анализирани съобразно нарастване на невроните в скритите слоеве в границите от 5 до 15. Резултатите от процедурите са поместени в таблица 3.1. По отношение на двата изследвани случая за преобладаваща част от анализираните модели са получени удовлетворяващи нива на точност около 90.0 % и 100 % при използване на една и две входни променливи. При приложение на “Uout” е регистрирана най-ниска точност 88.50 % при 7 междинни неврона, докато при “F and Uout” минималното показание на критерия, установено при 7 и 10 скрити неврона се равнява на 98.10 %.

На базата на представените резултати са синтезирани най-добри архитектури, показани на фиг. 3.9, при 6 при единично и 11 неврона в междинните слоеве при комбинирано входно въздействие. Моделите са изградени на основата на тангенс-сигмоидални и softmax функции на активация в изходните слоеве. Тук констатираните най-високи точности и най-ниски стойности на индикатора Cross-Entropy са 90.40 % и 1.10373e-0 при първата и 100.00% и 2.94522e-0 за втората селектирана най-добра архитектура.




**Фиг. 3.9.** FFNN за количествена идентификация на тензорезисторни преобразуватели при а) една и б) две входни променливи


Направена е допълнителна оценка и анализ на качествата на синтезираните FFNNs за количествена идентификация на тензорезистивни преобразуватели по отношение на:

- ❖ Cross-Entropy във връзка с обучаващите, валидиращите и тестовите процеси (фиг. 3.10);
- ❖ изходните матрици на коректни и некоректни класификации за основните мрежови процеси „обучение“, „валидация“ и „тестване“, които са дадени на фиг. 3.11;

По отношение на Cross-Entropy кривите не са констатирани индикации за преобучение на моделите, за които са наблюдавани подобни вариационни тенденции. Достигнати са най-добри валидиращи производителности 0.51948 при 1-ва и 0.058209 при 9-та итерация в ход на обучение с продължителност от 7 и 15 цикъла.



a)



б)

**Фиг. 3.10.** Cross-Entropy за синтезираните FFNN за количествена идентификация на тензорезисторни преобразуватели при а) една и б) две входни променливи

Класификационните матрици показват разположението на еталоните с правилно и некоректна принадлежност към дадена изходна група. Относно индивидуално използване на „изходното напрежение на мостовата схема“ са постигнати нива на точност 91.7 %, 75.0 % и 100.0 %, респективно при обучение, валидиране и тестване. В случая на прилагане на „въздействащата входна неелектрическа величина“ като втори информативен признак бяха констатирани идентични точности от класификация, равняващи се на 100.0 % са всички указани процеси, определящо предимствата на втория невронен модел.



**Фиг. 3.11.** Класификационни матрици за синтезираните FFNN за количествена идентификация на работни преобразуватели при а) една и б) две входни променливи

### 3.6. Изследване на невронни модели с обратно разпространение на грешката за идентификация на работни преобразуватели при въздействие на сили върху метали при Levenberg-Marquardt обучение

Реализирани са действия по аналогия на предходните при синтез на модели за качествен анализ на информация, придобита от тензорезисторни преобразуватели. Дейностите бяха приложени по отношение на изкуствени невронни мрежи с обратно разпространение на грешката (FFNNs) при използване на най-бързият обучаващ алгоритъм, наречен алгоритъм на Levenberg-Marquardt (LM алгоритъм). Анализираните невронни архитектури се състоят от:

- ❖ входен слой;
- ❖ междинен слой със зададена тангенс-симмоидална функция на активация;
- ❖ изходен слой при линейна активационна функция.

В таблици 3.2 и 3.3 са обобщени данни относно критериите за качество при подбор на невронни модели:

- ❖ точност от разпознаване и класификация;
- ❖ средноквадратична грешка.

Тук отново е следван подходът за невронна селекция при подаване на една “F” и комбинация от две входни променливи “F и Uout” за прогнозиране на работещите тензорезисторни преобразуватели. Изследвани са архитектури с вариации на междинните невронни единици в интервала от 5 до 15. Изходните групи, съответно:

- ❖ „един работен преобразувател“;
- ❖ „два работни преобразувателя“,

са дефинирани чрез отделни изходни неврони и дискретни кодови комбинации, определящи тяхната функционална принадлежност. При невронно обучение са използвани набори, съдържащи 52 информационна еталона (по 26 за всеки тестови клас).

**Таблица 3.2.** Резултати при изследване на изкуствени невронни мрежи с една входна променлива при LM обучение


Скрити неврони	Точност, %	Средноквадратична грешка
5	87.5	0.0973
6	62.5	0.1861
7	62.5	0.2590
8	87.5	0.1447
9	<b>100.0</b>	<b>0.0832</b>
10	50.0	0.3517
11	75.0	0.2813
12	62.5	0.4670
13	87.5	0.1331
14	75.0	0.1585
15	50.0	0.3843

**Таблица 3.3.** Резултати при изследване на изкуствени невронни мрежи при две входни променливи при LM обучение

Скрити неврони	Точност, %	Средноквадратична грешка
5	87.5	0.0349
6	<b>100.0</b>	<b>9.9631e-04</b>
7	87.5	0.0694
8	100.0	0.0065



9	100.0	0.0176
10	100.00	0.0029
11	100.0	0.0044
12	100.0	0.0349
13	87.5	0.1139
14	100.00	0.0124
15	87.5	0.0818



**Фиг. 3.13.** Синтезирани модели при LM обучение за идентификация на тензорезисторни преобразуватели при а) една и б) две входни променливи

В резултат от проведеното изследване при мрежата с една променлива е наблюдаван сравнително по-голям диапазон на промяна на точността от 50.0% при 15 до 100.0% при 9 неврона. Подобен извод може да бъде направен по отношение на втория критерии, изменящ се от 0.0832 при 9 до 0.4670 при 12 скрити неврона. Спрямо невронните модели при две постъпващи входни променливи максимална точност 100.0% е установена при 6, 8-12 и 13 неврона. Минималната средноквадратична грешка се равнява на  $9.9631e-04$  при 6, докато най-високите нейни нива достигат 0.1139 при 13 невронни единици. Селектираните мрежи с най-добри показатели при 9 и 6 неврона в скритите слоеве в случаите с една и две входни променливи са показани на фиг. 3.13.

### 3.7. Прогнозен анализ на силата на натоварване върху метали в мостова схема за включване на тензорезисторни преобразуватели посредством FFNN архитектури

Изследвани са FFNNs с линейна изходна активация при LM обучаващ алгоритъм за апроксимация на следните функции на преобразуване:

- ❖ “ $F = f(U_{out1})$ ”;
- ❖ “ $F = f(U_{out2})$ ”;
- ❖ “ $F = f(U_{out1} \text{ and } U_{out2})$ ”;

където  $U_{out1}$  и  $U_{out2}$  са измерените напрежения на мостовата схема на включване на един и два работни чувствителни елемента. Базисен критерии при подбор на модел за прогнозен анализ на натоварването върху опитни метални образци е средноквадратичната грешка, анализирана по аналогия на предходната задача при изменение на неврони в скрития слой в границите 5 до 15. Относно процесите на невронна селекция бяха зададени процентни съотношения между данните от входния информационен набор, както следва 50 % за обучение, 25 % при валидиране и 25 % за тестови процедури.


Таблица 3.4 съдържа данни за регистрираните стойности на грешката за трите изследвани типа невронни архитектури. При приложение на индивидуални входни променливи “ $U_{out1}$ ” и “ $U_{out2}$ ” са регистрирани минимални стойности  $MSE = 0.3302$  и  $MSE = 0.5114$ , респективно при 8 и 7 неврона в

междинните слоеве. Намерените максимални нива на грешката са съответно 26.6503 при 15 и 33.2414 за 13 скрити структурни единици. Сравнявайки получените грешки с тези при модели с две входни променливи “U<sub>out1</sub> and “U<sub>out2</sub>” се виждат по-добрите качества при вторите, където MSE се изменя в значително по-ниски нива в крайния интервал от 0.0029 до 0.9412, съответно при 5 и 15 междинни неврона.


**Таблица 3.4.** Изследване на FFNN архитектури за апроксимация при една и две входни променливи

Скрити неврони	MSE при U <sub>out1</sub>	MSE при U <sub>out2</sub>	MSE при U <sub>out1</sub> и U <sub>out2</sub>
5	0.5971	8.0906	<b>0.0029</b>
6	1.9451	16.0860	0.0152
7	0.9674	0.5114	0.0722
8	<b>0.3302</b>	1.5668	0.6968
9	0.4279	<b>0.3582</b>	0.0885
10	11.9616	32.7781	0.4661
11	24.7131	2.3140	0.5848
12	2.9257	22.2944	0.6491
13	23.3295	33.2414	0.0052
14	19.8530	23.1725	0.5929
15	26.6503	27.7549	0.9412

Според резултатите за целите на прогнозния анализ е селектирани невронни архитектури с наличие на 8, 7 и 5 изчислителни единици в скрития слой, респективно при подаване на “U<sub>out1</sub>”, “U<sub>out2</sub>” и “U<sub>out1</sub> and “U<sub>out2</sub>”. Фигура 3.17 онаглежда моделите относно информативни признаци “U<sub>out2</sub>” и “U<sub>out1</sub> and “U<sub>out2</sub>”.



a)



б)

**Фиг. 3.17.** Селектирани FFNNs за прогнозиране на силови въздействия върху метали при включване на мостова схема с тензорезисторни преобразуватели при подаване на а) “U<sub>out2</sub>” и б) “U<sub>out1</sub> and “U<sub>out2</sub>” входни променливи

### 3.8. Извеждане на линейни регресионни модели за прогнозиране на силови въздействия върху метали

Първата част от изследванията, касаещи синтез на модели за количествен анализ на сили на въздействие върху опитни метални образци, се състои в прилагане на инструмента на регресионния

анализ. Във връзка са дефинирани две информационни категории, включващи по 26 записа за всяка група с:

- ❖ изходен параметър “сила F” с въведено означение “y”;
- ❖ управляеми фактори на обекта “регистрирано изходно напрежение от мостовата измервателна схема с включване на един “U<sub>out1</sub>” и два работни преобразувателя “U<sub>out2</sub>” с обозначаващ етикет “x”.

Приложени са регресионни процедури върху опитните данни в продукта Statistica 10 за проверка на пригодността на модели от нулева степен като бяха наблюдавани резултати с много добри индикации за качество, показани на фиг. 3.29.

Regression Summary for Dependent Variable: y (danninew)						
R= ,99948781 R <sup>2</sup> = ,99897588 Adjusted R <sup>2</sup> = ,99893320						
F(1,24)=23411, p<0,0000 Std.Error of estimate: ,29978						
N=26	b*	Std.Err. of b*	b	Std.Err. of b	t(24)	p-value
Intercept			-0,4749	0,122680	-3,8707	0,000730
x	0,999488	0,006532	394,7272	2,579826	153,0054	0,000000

a)

Regression Summary for Dependent Variable: y (danninew)						
R= ,99943534 R <sup>2</sup> = ,99887101 Adjusted R <sup>2</sup> = ,99882396						
F(1,24)=21234, p<0,0000 Std.Error of estimate: ,31475						
N=26	b*	Std.Err. of b*	b	Std.Err. of b	t(24)	p-value
Intercept			-0,4334	0,128564	-3,3714	0,002529
x	0,999435	0,006859	788,5744	5,411632	145,7184	0,000000

б)

**Фиг. 3.29.** Регресионни резултати относно модели при а) 1 и б) 2 преобразувателя

$$y = -0.4749 + 394.7272x_1 \quad (3.1)$$

$$y = -0.4344 + 788.5744x_1 \quad (3.2)$$

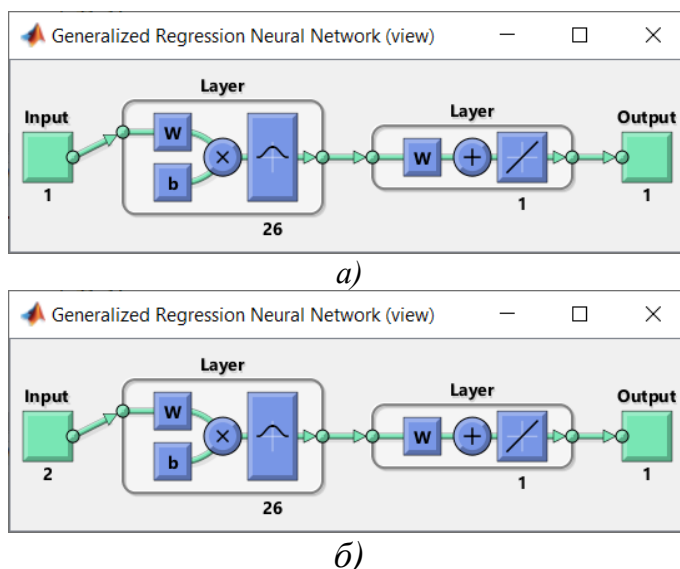
Спрямо прието базово равнище на значимост  $\alpha=0.05$  при не бяха констатирани незначими опитните коефициенти на регресия  $b_i$ . Получените критерии на Фишър  $F(1,24) = 23411$  и  $F(1,24) = 21234$ , както и съответните им вероятности  $p < 0.0000$ , определят изведените модели и относно прогнозиране на сили при постановки с включване на един (3.1) и два работни чувствителни сензорни елемента (3.2) като адекватни и описващи напълно опитните данни в хода на проведената диагностика. По отношение на коефициентите на определеност  $R^2$  спрямо получените прогнозни модели са установени близки високи нива, съответно  $R^2 = 0.99897588$  при един и  $R^2 = 0.99887101$  при два детектиращи тензорезистора, потвърждаващо високото качество на прогнозните регресионни модели.

### 3.9. Изследване и подбор на модели за прогнозен анализ във връзка с силови въздействия върху метални обекти на основата на обобщени регресионни невронни мрежи при два работни преобразувателя

Друг тип изкуствени невронни мрежи, които могат да бъдат използвани като база за създаване на модели за прогнозен количествен анализ на потенциални сили на въздействие върху метални обекти е този на обобщените регресионни невронни мрежи (Generalized Regression Neural Networks). Подход в изследванията, базирани на GRNN, е изпълнение на тестове на архитектури при задаване на различен брой входни променливи. В начален етап беше анализирано поведението на невронни мрежи при подаване на един и комбинация от указаните три информативни признака, респективно U<sub>out</sub>,  $\Delta R/R$  и  $\Delta I/I$ . Бяха получени силно завишени показания за MSE в целия диапазон на изменение на широчината на радиално-базисните функции и при двата случая. Вследствие на това моделите с три входни променливи бяха изключени. След което бяха последователно оценени невронни архитектури с различни комбинации от два признака и такива с подаване на индивидуални променливи. Бяха констатирани негативни тенденции относно използване на „измереното изходно напрежение в индикаторния диагонал на моста“ и по-добри, но все още незадоволителни резултати при приложение на останалите два индивидуални информативни признака  $\Delta R/R$  и  $\Delta I/I$ .

Таблица 3.6 съдържа обобщени данни относно архитектури при използване на една променлива “ $\Delta R/R$ ” (фиг. 3.32.а) и комбинацията от две входни променливи с най-добри качествени показатели “ $\Delta R/R$  и  $\Delta I/I$ ” (фиг. 3.32.б), с цел по коректно представяне на цялостния процес на оценка от страна на негативна и положителна гредна точка. В процедурите на синтез по отношение на двата

типа обобщени регресионни невронни архитектури са използвани идентични диапазони на широчината на функциите от радиално-базисния слой, както следва от „0.8“ до „0.98“ при постоянна стъпка на увеличаване на индикатора „0.01“. По аналогия с изследванията при FFNN, тук е анализиран базовия критерий MSE. В хода на процесите по селекция на модели при прилагане на един и комбинация от два информативни признака е установена еднаква тенденция плавно нарастване на средноквадратичната грешка. При най-ниска стойност на “spread” са наблюдавани най-ниски MSE вариации. Силно негативна индикация е наблюдаваното при GRNN на базата на променлива “ $\Delta R/R$ ”, свързана със значително в десетки пъти превишаване на нивата на MSE в сравнение с модели при подадени “ $\Delta R/R$ ” и “ $\Delta I/I$ ”. При архитектура с един информативен признак е констатирана минимална средноквадратична грешка 22.3324, докато при невронната мрежа с две входни променливи грешката се равнява едва на незначителна стойност  $8.6830e-17$ .



Фиг. 3.32. Изследвани GRNN модели за прогнозен анализ на силовото натоварване при а) една и б) две входни променливи

Таблица 3.6. Резултати от синтез на RGNN архитектури за случаите на един и комбинация от два информативни признака

№	Spread индикатор	Средноквадратична грешка – MSE показател	
		$\Delta R/R$	$\Delta R/R$ и $\Delta I/I$
1.	0.80	22.3324	$8.6830e-17$
2.	0.81	22.9465	$2.0387e-16$
3.	0.82	23.5604	$4.6403e-16$
4.	0.83	24.1738	$1.0255e-15$
5.	0.84	24.7861	$2.2032e-15$
6.	0.85	25.3969	$4.6084e-15$
7.	0.86	26.0060	$9.3955e-15$
9.	0.87	26.6129	$1.8693e-14$
10.	0.88	27.2173	$3.6335e-14$
11.	0.89	27.8189	$6.9071e-14$
12.	0.90	28.4173	$1.2853e-13$
13.	0.91	29.0124	$2.3436e-13$
14.	0.92	29.6037	$4.1908e-13$
15.	0.93	30.1911	$7.3556e-13$
16.	0.94	30.7744	$1.2682e-12$
17.	0.95	31.3532	$2.1493e-12$

Относно целите на прогнознит анализ беше избрана архитектура на обобщена регресионна невронна мрежа с най-адекватна MSE оценка при подаване на относителните изменения на съпротивлението и дължината на чувствителните сензорни елементи при ниво на spread индикатора „0.8“.

### Изводи към трета глава

- ❖ Разработена е експериментална система за следене, филтрация, регистрация, изследване и статистически анализ на неелектрически силови въздействия върху изпитвани метални обекти и редуциране на шумове с WEB достъп на базата на тензорезисторни преобразуватели, многофункционален модул NI 6002, виртуална платформа LabVIEW, софтуерни цифрови филтриращи звена, изкуствен интелект и регресионна диагностика;
- ❖ Систематизиран е подход за количествена идентификация на включените работни сензорни преобразуватели и прогнозен анализ на силовите натоварвания при изпитване на метални образци на основата на обработка и анализ на експериментално придобити данни чрез изкуствени невронни мрежи и регресионен анализ;
- ❖ Проведени са тестове касаещи работоспособността на проектираната система и са придобити опитни данни, използвани като информационна основа за синтез на модели за качествен и количествен анализ на данни от тензорезисторни преобразуватели;
- ❖ Синтезирани са архитектури на изкуствени невронни мрежи с пряко разпространение на сигналите и обратно разпространение на грешката при Levenberg-Marquardt и Scaled Conjugate Gradient алгоритми на обучение, оценени чрез въведен набор от индикатори за качество, за идентификация на оперативните сензорни елементи към мостова на схема на тяхно включване при измерване на сили;
- ❖ Създадени са невронни модели с обратно разпространение на грешката на база на извършена селекция на входни информативни признаци с цел прогнозен анализ на потенциални сили на натоварване при изпитване тензорезисторни преобразуватели върху тестови метални обекти;
- ❖ Изведени са линейни математически модели с помощта на регресионен анализ и модели на основата на обобщени регресионни невронни мрежи при различни случаи на входни променливи за прогнозен анализ на силови въздействия при изпитване на тестови метални обекти с включване тензорезистивни чувствителни елементи.

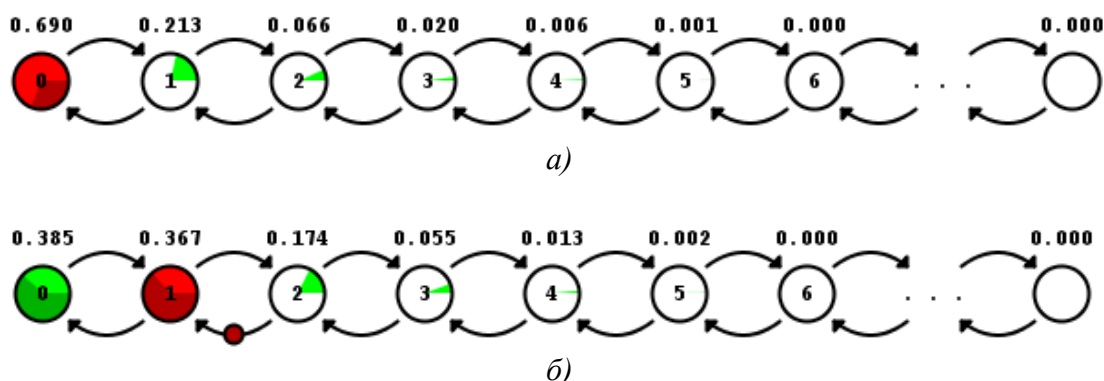
## ГЛАВА IV. ПРОГНОЗЕН АНАЛИЗ НА ТРАФИКА В ИМИТАЦИОННО МОДЕЛИРАНИ ИНФОРМАЦИОННО-КОМУНИКАЦИОННИ КАНАЛИ ОТ ВИДА ВЕРИГИ НА МАРКОВ

### 4.1. Имитационно моделиране на телетрафични системи от вида „вериги на Марков“ във връзка със синтез на модели за прогнозен анализ относно обслужването на системни потребители

Бяха проведени серия от изследвания във връзка с имитационно моделиране на вериги на Марков M/M/1 и M/M/c/k при  $c = 15$  и натрупване на няколко категории от опитни. По отношение на формираните информационни набори се цели да бъдат получени модели за прогнозен анализ на постъпващия и обработвания трафик с помощта на набор от различни математически апарати. Процедурите са извършени спрямо дефинирани фактори или параметри при телетрафична симулация, както следва:

- Avg. Arrival Rate ( $x_1$ ) – зададена средна скорост на постъпване на заявки към оперативните сървърни станции;
- Avg. Service Time ( $x_2$ ) – фиксирано средно време на обработка на постъпили входящи заявки;
- Max Station Capacity  $k$ , ( $x_3$ ) – задаван максимален брой повиквания в опашката, както и отклици на обекта при вериги на Марков M/M/1 и M/M/c/k при  $c = 15$ , съответно:

- Avg. Cust. N in Station ( $y_1$ ) – среден брой потребители в опашката + средно количество обслужвани заявки;
- Avg. Response Time ( $y_2$ ) – средно време за престой в опашката + средно време за обслужване на заявките.



Фиг. 4.1. Диаграми на преходите при имитационно моделиране на телетрафична система а) M/M/1 и б) M/M/c/k при  $c = 15$

Фигура 4.1 представя диаграми на преходите относно моментни състояния в условията на симулация на изследваните Марковски вериги. В хода на процесите по имитационно моделиране бяха обособени информационни набори от опитни данни респективно, както за обучение, така и за процедури по верификация относно проверка на тяхната адекватност.

### 4.3. Приложение на регресионния апарат за извеждане на модели за прогнозен анализ по отношение на обслужването на системни потребители при верига на Марков M/M/1 в програмна среда STATISTICA

#### 4.3.1. Проверка на адекватността на базови аналитични модели от нулева, първа и втора степен относно прогнозен анализ на параметри на трафика

В начален етап на представените изследвания беше разгледана възможността за извеждане на прогнозни модели във връзка с телетрафична система с неограничена опашка и една сървърна станция на основата на класическия регресионен анализ. За целта беше заложена проверка на адекватността на базисни аналитични линейни и полиномиални модели, дадени по-долу:

$$y = b_0 + b_1x_1 + b_2x_2 \quad (4.1)$$

$$y = b_0 + b_1x_1 + b_2x_2 + b_{12}x_1x_2 \quad (4.2)$$

$$y = b_0 + b_1x_1 + b_2x_2 + b_{12}x_1x_2 + b_{11}x_1^2 + b_{22}x_2^2 \quad (4.3)$$

Анализът относно параметрите на обекта  $y_1$  и  $y_2$  беше приложен с помощта на програмен пакет STATISTICA 10. След дефиниране на разширената матрица се премина към приложение на регресионния апарат, резултатите, от които са показани на фиг. 4.4 и фиг. 4.5.

Резултатите показват получени най-ниски степени на коефициентите на определеност  $R^2$  относно линейните модели за прогнозиране на вариациите на „среден брой заявки в опашката + средното обслужвано количество заявки“ и „средното общо време от продължителността на престой в опашката и обработка на заявки“ за дадена сървърна станция. Установени са следните коефициенти  $R^2 = 0.56457109$  и  $R^2 = 0.65195915$  за отклиците на обекта  $y_1$  и  $y_2$ , определящи модел (4.1) като неадекватен относно целта на изследването.

Regression Summary for Dependent Variable: y1 (m-m-1)						
R= ,75137946 R <sup>2</sup> = ,56457109 Adjusted R <sup>2</sup> = ,53818146						
F(2,33)=21,394 p<,00000 Std.Error of estimate: 1,0366						
N=36	b*	Std.Err. of b*	b	Std.Err. of b	t(33)	p-value
Intercept			-2,42048	0,550424	-4,39749	0,000108
x1	0,504320	0,114869	4,44143	1,011622	4,39040	0,000110
x2	0,556985	0,114869	1,88663	0,389085	4,84889	0,000029

a)

Regression Summary for Dependent Variable: y1 (m-m-1)						
R= ,90029822 R <sup>2</sup> = ,81053688 Adjusted R <sup>2</sup> = ,79277471						
F(3,32)=45,633 p<,00000 Std.Error of estimate: ,69438						
N=36	b*	Std.Err. of b*	b	Std.Err. of b	t(32)	p-value
Intercept			0,92390	0,636538	1,45144	0,156391
x1	-0,445059	0,166183	-3,91953	1,463532	-2,67813	0,011587
x2	-0,604608	0,195959	-2,04794	0,663757	-3,08537	0,004172
x12	1,580058	0,245145	9,83642	1,526114	6,44540	0,000000

б)

Regression Summary for Dependent Variable: y1 (m-m-1)						
R= ,94190570 R <sup>2</sup> = ,88718634 Adjusted R <sup>2</sup> = ,86838407						
F(5,30)=47,185 p<,00000 Std.Error of estimate: ,55339						
N=36	b*	Std.Err. of b*	b	Std.Err. of b	t(30)	p-value
Intercept			3,3100	0,757580	4,36915	0,000137
x1	-1,40401	0,361046	-12,3648	3,179645	-3,88873	0,000518
x2	-1,56469	0,315829	-5,3000	1,069781	-4,95424	0,000027
x12	1,58006	0,195369	9,8364	1,216242	8,08755	0,000000
x11	0,97480	0,341430	10,5565	3,697493	2,85506	0,007734
x22	0,98375	0,281281	1,9130	0,546966	3,49738	0,001487

в)

**Фиг. 4.4.** Регресионни резултати при проверка на адекватността на модели а) (4.1), б) (4.2) и в) (4.3) относно параметър  $y_1$  при верига на Марков М/М/1

При използването на полиномиални модели от съответна степен беше наблюдавано повишаване на нивата на  $R^2$  относно прогнозните параметри на обслужвания трафик. От анализ на пригодността на модел (4.2) бяха регистрирани регресионни оценки на определеност от порядъка на нива от „0,81“ и „0,83“. По отношение на модела от втора степен беше констатирано, че 88.718634 % от изменението  $y_1$  и 91.163600 % от вариациите на изходен параметър  $y_2$  са резултат от въздействието на управляемите фактори. Останалите 11.281366 % и 8.937000 % от промяната на телетрафичните параметри се дължи на случайни смущаващи въздействия.

Regression Summary for Dependent Variable: y2 (m-m-1)						
R= ,80743987 R <sup>2</sup> = ,65195915 Adjusted R <sup>2</sup> = ,63086576						
F(2,33)=30,908 p<,00000 Std.Error of estimate: 1,4225						
N=36	b*	Std.Err. of b*	b	Std.Err. of b	t(33)	p-value
Intercept			-3,24818	0,755325	-4,30038	0,000142
x1	0,392648	0,102697	5,30762	1,388209	3,82336	0,000554
x2	0,705540	0,102697	3,66813	0,533926	6,87011	0,000000

a)

Regression Summary for Dependent Variable: y2 (m-m-1)						
R= ,91477834 R <sup>2</sup> = ,83681942 Adjusted R <sup>2</sup> = ,82152124						
F(3,32)=54,701 p<,00000 Std.Error of estimate: ,98912						
N=36	b*	Std.Err. of b*	b	Std.Err. of b	t(32)	p-value
Intercept			1,20203	0,906727	1,32568	0,194333
x1	-0,430398	0,154226	-5,81791	2,084752	-2,79070	0,008793
x2	-0,301481	0,181860	-1,56741	0,945500	-1,65776	0,107139
x12	1,369801	0,227507	13,08885	2,173898	6,02092	0,000001

б)

Regression Summary for Dependent Variable: y2 (m-m-1)						
R= .95479631 R²= .91163600 Adjusted R²= .89690867						
F(5,30)=61.901 p<.00000 Std.Error of estimate: .75174						
N=36	b*	Std.Err. of b*	b	Std.Err. of b	t(30)	p-value
Intercept			4,4735	1,029119	4,34688	0,000146
x1	-1,12033	0,319535	-15,1441	4,319322	-3,50613	0,001453
x2	-1,38837	0,279517	-7,2182	1,453222	-4,96704	0,000026
x12	1,36980	0,172907	13,0889	1,652178	7,92218	0,000000
x11	0,70134	0,302175	11,6577	5,022781	2,32097	0,027270
x22	1,11368	0,248942	3,3240	0,743015	4,47366	0,000102

в)

**Фиг. 4.5.** Регресионни резултати при проверка на адекватността на модели а) (4.1), б) (4.2) и в) (4.3) относно параметър  $y_2$  при верига на Марков M/M/1

Въз основа на прието равнище на значимост  $\alpha = 0.05$  и установените критерии на Фишър  $F(5,30) = 47.185$  и  $F(5,30) = 61.901$ , както и съответните им вероятности  $p$  по-малки от  $\alpha$ , за отклици на обекта  $y_1$  и  $y_2$  дават основание модел (4.3) да се дефинира като най-пълно описващ опитните данни и най-висока степен на адекватност. Относно модела опитните коефициенти на регресия  $b_0, b_1, b_2, b_{12}, b_{11}$  и  $b_{22}$  са определени като значими.

$$y_1 = 3.3100 - 12.3648x_1 - 5.3000x_2 + 9.8364x_1x_2 + 10.5565x_1^2 + 1.9130x_2^2 \quad (4.4)$$

$$y_2 = 4.4735 - 15.1441x_1 - 7.2182x_2 + 13.0889x_1x_2 + 11.6577x_1^2 + 3.3240x_2^2 \quad (4.5)$$

На база на проведената регресионна диагностика са изведени крайни модели (4.4) и (4.5) за прогнозен анализ на целевите параметри на обработвания трафик от дадена структурна сървърна станция  $y_1$  и  $y_2$ , представени по-горе. Във връзка с качествата на получените прогнозни аналитични модели може да се каже, че очакваните нива на коефициента на определеност  $R^2$  около „0.91“ при прогнозен анализ на  $y_2$  се приемат като удовлетворяващи. При прогнозиране на количествените изменения на трафичното натоварване – параметър  $y_1$ , поради по-занижените степени на сходство между теоретичните и прогнозните резултати е налице основание за търсене на по-адекватни математически инструменти за прогнозен анализ.

#### 4.5. Синтез на GRNN модели за прогнозен анализ на обслужваните потребителски заявки на сървърни станции при верига M/M/c/k при различни входни променливи и обучаващи алгоритми

В следващ етап беше преминато към изследвания, насочени към регресионно моделиране, анализ и оценка на ефективността на един от видовете изкуствени невронни мрежи, които са специфицирани за целите на прогнозни анализи – обобщени регресионни невронни архитектури. Обект на прогнозен анализ е „средното количество заявки, предстоящи за извикване на опашката, добавени към средния брой обработвани заявки от системна сървърна станция (параметър  $y_1$ )“ е Марковска верига M/M/15/k. Създадени и анализирани са GRNN при строго дефинирани 45 структурни изчислителни единици в радиално-базисните слоеве. Същинските процеси на изследване бяха разделени в три фази, състоящи се в синтез на GRNNs на базата на различни количество от обучаващи променливи, съответно:

- единични входни въздействия;
- комбинации от два управляеми фактора;
- набор от три независими информативни признака.

Бяха оценени два базисни показателя, респективно “Mean Squared Error” и “Mean Absolute Error (MAE)”, при стъпково нарастване на „spread“ критерия при идентични нива от „0.15“ до „0.95“ относно структурните неврони с радиално-базисните слоеве. Резултатите от анализ на невронната функционалност са последователно обобщени от таблица 4.5 до таблица 4.7.



Прилагането на индивидуални входни променливи  $x_1$  и  $x_2$  се свързва с наблюдавани значителни степени на нарастване на показателите за качество при увеличаване на широчината на радиално-базисните функции. Регистрирани са следните вариационни диапазони за:

- ❖ MSE от 0.0090 до 0.2583 при  $x_1$  и от 0.0012 до 0.1478 за променлива  $x_2$  за дефинираните гранични стойности на spread индикатора;
- ❖ MAE показател, изменящ се от 0.0642 до 0.4374 при spread = 0.15 за фактор  $x_1$  и от 0.0180 до 0.3267 за spread = 0.95 относно фактор  $x_2$ .

Съпоставяйки резултатите по отношение на двата типа тестови GRNN архитектури се наблюдава предимство при подаване на  $x_1$  спрямо управляващо въздействие  $x_2$ . Значително подобряване на показателите беше установено при модели с подаване на входна променлива  $x_3$ . Тук минималните получени средноквадратични и средни абсолютни грешки се равняват на  $5.1444e-04$  и 0.0202 при модели за spread стойности “0.15”, “0.20”, “0.25”, “0.30”, “0.35”, “0.40” и “0.45”. Бяха констатирани максимални MSE =  $6.4079e-04$  и MAE = 0.0213 при най-висока граница на spread индикатора.

**Таблица 4.5.** MSE и MAE показатели при синтез на обобщени регресионни невронни мрежи за прогнозиране на обслужваните заявки при верига на Марков M/M/c/k при прилагане на индивидуални входни променливи

Spread индикатор	MSE	MAE	MSE	MAE	MSE	MAE	
	$x_1$		$x_2$		$x_3$		
0.15	0.0090	0.0642	0.0012	0.0180	5.1444e-04	0.0202	
0.20	0.0202	0.1054	0.0028	0.0307			
0.25	0.0371	0.1514	0.0054	0.0464			
0.30	0.0591	0.1980	0.0091	0.0640			
0.35	0.0843	0.2413	0.0140	0.0838			
0.40	0.1100	0.2791	0.0203	0.1053			
0.45	0.1344	0.3107	0.0282	0.1283			
0.50	0.1564	0.3368	0.0375	0.1521	5.1758e-04	0.0203	
0.55	0.1757	0.3581	0.0483	0.1761	5.2206e-04		
0.60	0.1923	0.3755	0.0601	0.1995	5.2912e-04		
0.65	0.2066	0.3897	0.0727	0.2222	5.3862e-04		
0.70	0.2188	0.4015	0.0857	0.2435	5.5033e-04		
0.75	0.2292	0.4113	0.0989	0.2633	5.6408e-04		0.0204
0.80	0.2382	0.4195	0.1118	0.2814	5.7987e-04		0.0207
0.85	0.2458	0.4264	0.1244	0.2979	5.9781e-04		0.0209
0.90	0.2525	0.4323	0.1364	0.3130	6.1805e-04		0.0211
0.95	0.2583	0.4374	0.1478	0.3267	6.4079e-04		0.0213

Във връзка с обучаващите процедури на GRNNs при използване на комбинации от две входни променливи бяха констатирани най-ниски индикации за качество при двойка “ $x_1$  and  $x_2$ ”. MSE варира от 0.020 до 0.1239 при spread нива “0.20” and “0.95”, докато MAE се изменя в интервала от 0.0251 до 0.2973. Изключение в изходните извадки за индикаторите са стойности на MSE =  $8.5469e-04$  and MAE = 0.0147 при най-малка фиксирана широчина на радиално-базисните функции, доближаващи се до постигнатите положителни близни индикации при комбинации “ $x_1$  and  $x_3$ ” и “ $x_2$  and  $x_3$ ”. Получени са количествени диапазони относно MSE and MAE при анализ на невронната функционалност, респективно от:

- ❖  $5.0812e-04$  до  $6.3866e-04$  относно средноквадратичната грешка и от 0.0201 до 0.0213 за средната абсолютна грешка при заложена стойност на показателя spread = 0.15;
- ❖  $4.8957e-04$  to  $6.3240e-04$  за MSE, както и от 0.0197 до 0.0212 във връзка с MAE индикатор.

Откроява се значително по-добрата ефективност при архитектури с приложени комбинации от променливи “ $x_1$  and  $x_3$ ” и “ $x_2$  and  $x_3$ ” спрямо GRNNs с единични входни въздействия “ $x_1$ ” and “ $x_2$ ”. Също така се забелязват леки преимущества при невронните мрежи, обучени на база втората - “ $x_1$  and  $x_3$ ”, пред останалите приложени двойки от управляеми фактори.

**Таблица 4.6.** MSE и MAE показатели при синтез на обобщени регресионни невронни мрежи за прогнозиране на обслужваните заявки при веригана Марков М/М/с/к при подаване на комбинации от две входни променливи


Spread индикатор	MSE	MAE	MSE	MAE	MSE	MSE
	$x_1$ и $x_2$		$x_1$ и $x_3$		$x_2$ и $x_3$	
0.15	8.5469e-04	0.0147	5.0812e-04	0.0201	4.8957e-04	0.0197
0.20	0.0020	0.0251	5.1088e-04	0.0202	5.0037e-04	0.0199
0.25	0.0039	0.0378	5.1216e-04		5.0541e-04	0.0200
0.30	0.0066	0.0527	5.1284e-04		5.0808e-04	0.0201
0.35	0.0102	0.0690	5.1317e-04		5.0936e-04	
0.40	0.0149	0.0871	5.1335e-04		5.0970e-04	
0.45	0.0207	0.1065	5.1397e-04		5.0993e-04	
0.50	0.0277	0.1269	5.1600e-04		5.1138e-04	0.0202
0.55	0.0359	0.1482	5.2030e-04		5.1515e-04	
0.60	0.0451	0.1694	5.2723e-04	0.0203	5.2170e-04	0.0202
0.65	0.0554	0.1906	5.3666e-04		5.3091e-04	
0.70	0.0664	0.2111	5.4833e-04	0.0204	5.4245e-04	0.0203
0.75	0.0778	0.2308	5.6206e-04		5.5611e-04	
0.80	0.0895	0.2494	5.7783e-04	0.0206	5.7183e-04	0.0205
0.85	0.1012	0.2667	5.9575e-04	0.0208	5.8968e-04	0.0207
0.90	0.1127	0.2826	6.1597e-04	0.0211	6.0981e-04	0.0210
0.95	0.1239	0.2973	6.3866e-04	0.0213	6.3240e-04	0.0212

Последната фаза от синтез на GRNN модели за прогнозен анализ се състои в оценка на MSE and MAE индикатори спрямо плавно увеличаване на spread параметъра за случая на използване на три входни променливи. При подаване на входна комбинация “ $x_1$ ,  $x_2$  and  $x_3$ ” бяха получени най-добри количествени индикатори в хода на направените изследвания, спрямо които указаната GRNN архитектура се оценява с най-висока степен на адекватност. Установени са числови диапазони от 4.8341e-04 до 6.3031e-04 относно MSE и от 0.0196 до 0.0211 за MAE критерии.


**Таблица 4.7.** MSE и MAE показатели при синтез на обобщени регресионни невронни мрежи за прогнозиране на обслужваните заявки при веригана Марков М/М/с/к при прилагане на три входни променливи

Spread индикатор	MSE	MAE
	$x_1$ , $x_2$ и $x_3$	
0.15	4.8341e-04	0.0196
0.20	4.9686e-04	0.0199
0.25	5.0315e-04	0.0200
0.30	5.0649e-04	0.0201
0.35	5.0809e-04	
0.40	5.0848e-04	
0.45	5.0859e-04	
0.50	5.0985e-04	
0.55	5.1345e-04	
0.60	5.1987e-04	
0.65	5.2899e-04	


0.70	5.4050e-04	0.0202
0.75	5.5414e-04	
0.80	5.6983e-04	0.0205
0.85	5.8766e-04	0.0207
0.90	6.0776e-04	0.0209
0.95	6.3031e-04	0.0211



a)



б)



в)

**Фиг. 4.15.** Изследвани архитектури на обобщени регресионни невронни мрежи за прогнозиране на обслужваните заявки при верига на Марков  $M/M/c/k$  при а) една, б) две и в) три входни управляеми фактора

На фиг. 4.15 е онагледен вида на анализираниите архитектури на обобщени регресионни невронни мрежи при една, две и три входни променливи. По отношение на целите на прогнозен анализ на потенциалното средно трафично натоварване на сървърни станции при верига  $M/M/c/k$  са избрани модели при комбинации “ $x_1$  and  $x_2$ ”, “ $x_1$  and  $x_3$ ”, “ $x_2$  and  $x_3$ ” и намерената с най-добри показатели GRNN при “ $x_1, x_2$  and  $x_3$ ” при най-малка широчина на радиално-базисните функции на ниво „0.15“.

#### 4.6. FFNN модели за прогнозен анализ на трафичното натоварване на сървърни станции при верига $M/M/c/k$ при различни входни променливи и обучаващи алгоритми

##### 4.6.1. Подбор на FFNN архитектури за прогнозен анализ на средния обслужван трафик от структурни сървърни станции при верига $M/M/c/k$

Базирайки се на установените предимства при получаване на прогнозни модели чрез изкуствен интелект се формира основа на разширяване на изследванията в това направление. Бяха извършени дейности по прилагане и анализ на функционалността на други видове мрежи с въвеждане на специфицирани условия и категории невронно обучение. В тази посока беше заложена задачата за синтез на FFNN модели при тангенс-сигмоидална и линейна активации за прогнозен анализ на параметъра “Avg. Cust. N in Station” по аналогия на GRNN при различни двойки променливи и три управляеми фактора на обекта в хода на следните обучаващи градиентни подходи:

- ❖ *Levenberg-Marquardt* алгоритъм;

- ❖ *Bayesian Regularization обучение;*
- ❖ *Scaled Conjugate Gradient алгоритъм.*

**Таблица 4.8.** Резултати при изследване на FFNN модели за прогнозен анализ при входни променливи  $x_1$  и  $x_2$  и различни алгоритми за обучение

Скрити неврони	Входни променливи $x_1$ и $x_2$					
	Levenberg-Marquardt		Bayesian Regularization		Scaled Conjugate Gradient	
	MSE при тестване	R при тестване	MSE при тестване	R при тестване	MSE при тестване	R при тестване
5	3.58376e-5	0.999956	1.62116e-5	0.999971	2.00065e-4	0.999805
6	1.95550e-5	0.999976	3.05737e-5	0.999974	1.12584e-2	0.986220
7	2.17066e-5	0.999962	1.87423e-5	0.999969	3.07503e-4	0.999364
8	1.25622e-5	0.999981	<b>7.87707e-6</b>	<b>0.999978</b>	4.15378e-3	0.994077
9	1.46942e-5	0.999978	2.88317e-5	0.999960	8.13698e-4	0.998838
10	3.57247e-5	0.999946	2.83059e-5	0.999971	1.62650e-2	0.979963
11	3.73982e-5	0.999944	2.07308e-5	0.999972	2.56892e-4	0.999629
12	1.184425e-4	0.999895	2.87987e-5	0.999973	2.79524e-2	0.982778
13	2.45482e-5	0.999989	4.27936e-5	0.999965	2.39668e-3	0.995858
14	4.49284e-5	0.999937	2.49110e-5	0.999975	1.773763e-3	0.995772
15	4.14351e-5	0.999962	4.09594e-5	0.999973	5.27899e-4	0.999341

Приети базисни критерии във връзка с оценка на ефективността са „средноквадратичната грешка“ и „корелационният коефициент“ като първият е с по-висока значимост. Показателите са отчетени съгласно тестовите процеси на целевите невронни архитектури при дефинирано количествено изменение на скритите неврони от 5 до 15 единици. Данните за разглежданите случаи на синтез са систематизирани от таблица 4.8 до таблица 4.11.

**Таблица 4.9.** Резултати при изследване на FFNN модели за прогнозен анализ при входни променливи  $x_1$  и  $x_3$  и различни алгоритми за обучение

Скрити неврони	Входни променливи $x_1$ и $x_3$					
	Levenberg-Marquardt		Bayesian Regularization		Scaled Conjugate Gradient	
	MSE при тестване	R при тестване	MSE при тестване	R при тестване	MSE при тестване	R при тестване
5	4.39720e-5	0.999950	2.11298e-5	0.999984	3.08028e-3	0.997355
6	1.62596e-5	0.999967	3.75225e-5	0.999961	2.45964e-3	0.998581
7	9.70807e-6	0.999989	2.01365e-5	0.999975	2.09834e-3	0.998711
8	6.50901e-5	0.999921	1.96413e-5	0.999973	1.01533e-3	0.998663
9	4.76781e-5	0.999924	1.14102e-5	0.999984	3.00404e-3	0.996675
10	7.33183e-5	0.999784	<b>4.38308e-6</b>	<b>0.999976</b>	9.57688e-3	0.995464
11	1.54755e-4	0.999930	2.32812e-5	0.999976	9.99734e-3	0.995764
12	1.17251e-4	0.999697	7.73285e-6	0.999972	1.254823e-2	0.995194
13	1.53007e-4	0.999793	1.27526e-5	0.999982	2.27819e-2	0.986049
14	1.04919e-3	0.998664	2.31026e-5	0.999977	4.48133e-4	0.998582
15	5.761154e-4	0.998698	1.36876e-5	0.999979	6.83172e-3	0.988135

**Таблица 4.10.** Резултати при изследване на FFNN модели за прогнозен анализ при входни променливи  $x_2$  и  $x_3$  и различни алгоритми за обучение

Скрити неврони	Входни променливи $x_2$ и $x_3$					
	Levenberg-Marquardt		Bayesian Regularization		Scaled Conjugate Gradient	
	MSE при	R при	MSE при	R при	MSE при	R при

	тестване	тестване	тестване	тестване	тестване	тестване
5	5.73373e-5	0.999882	1.19938e-5	0.999987	6.09723e-3	0.993193
6	1.44124e-4	0.999923	1.65318e-5	0.999974	7.84788e-2	0.862890
7	1.67926e-5	0.999973	1.99778e-5	0.999971	9.70160e-3	0.998716
8	1.75572e-5	0.999964	2.68760e-5	0.999966	4.46214e-4	0.999649
9	5.71159e-5	0.999927	1.45921e-5	0.999981	4.12709e-3	0.994168
10	1.32510e-4	0.999911	1.39287e-5	0.999967	1.06766e-3	0.999101
11	1.12462e-4	0.999871	1.45404e-5	0.999976	3.63054e-3	0.996383
12	6.16591e-5	0.999860	<b>8.52469e-6</b>	<b>0.999976</b>	5.19627e-3	0.993164
13	2.86715e-5	0.999954	1.17933e-5	0.999979	7.51613e-3	0.994223
14	2.63716e-4	0.999828	1.43185e-5	0.999985	3.04749e-3	0.994463
15	8.37373e-4	0.999076	2.66765e-5	0.999978	1.81558e-3	0.997741

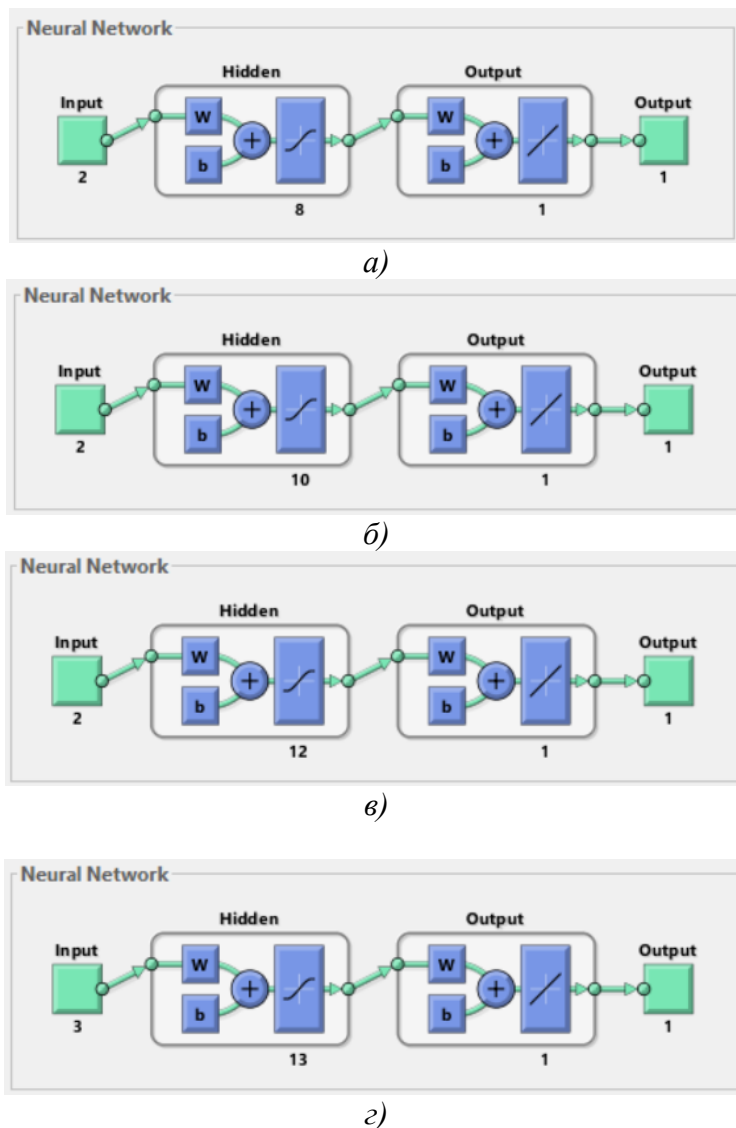
Според изложените резултати при комбинации от фактори:

- ❖ “ $x_1$  and  $x_2$ ” са получени най-ниски стойности  $MSE = 1.184425e-4$ ,  $MSE = 7.87707e-6$  и  $MSE = 2.00065e-4$ , съответно при 12, 8 и 5 скрити неврона при LM, BR и SCG обучаващи алгоритми;
- ❖ “ $x_1$  and  $x_3$ ” бяха регистрирани минимални средноквадратични грешки при LM “ $1.62596e-5$ ”, BR “ $4.38308e-6$ ” and SCG “ $4.48133e-4$ ” при структури с 6, 10 и 14 междинни неврона;
- ❖ “ $x_2$  and  $x_3$ ” са отчетени най-малки степени на грешката, респективно „ $1.67926e-5$ “ при 7 скрити неврона за LM algorithm, „ $8.52469e-6$ “ за архитектура с 12 междинни изчислителни единици относно BR обучение и „ $4.46214e-4$ “ във връзка с FFNN модел при 8 междинни неврона и използване на SCG подход;
- ❖ “ $x_1$ ,  $x_2$  and  $x_3$ ” бяха установени минимални показания  $MSE = 1.92693e-5$ ,  $MSE = 8.88908e-6$  and  $MSE = 1.67612e-4$ , следователно при 6, 13 и 9 структурни скрити неврона при последователно прилагане на LM, BR и SCG алгоритми.

**Таблица 4.11.** Резултати при изследване на FFNN модели за прогнозен анализ при входни променливи  $x_1, x_2$  и  $x_3$  различни алгоритми за обучение

Скрити неврони	Входни променливи $x_1, x_2$ и $x_3$					
	Levenberg-Marquardt		Bayesian Regularization		Scaled Conjugate Gradient	
	MSE при тестване	R при тестване	MSE при тестване	R при обучение	R при валидиране	R при тестване
5	4.45379e-5	0.999953	1.84230e-5	0.999949	4.25524e-4	0.999586
6	1.92693e-5	0.999974	3.52834e-5	0.999977	2.09231e-3	0.998037
7	2.03792e-4	0.999765	2.75634e-5	0.999975	1.79957e-3	0.997545
8	5.36125e-5	0.999932	1.19765e-5	0.999982	4.03832e-3	0.999654
9	2.52754e-5	0.999972	2.78891e-5	0.999986	1.67612e-4	0.999211
10	2.96257e-5	0.999971	2.05384e-5	0.999990	1.19369e-3	0.998780
11	2.17546e-5	0.999946	2.27914e-5	0.999955	3.40757e-3	0.991529
12	5.18882e-5	0.999932	1.43303e-5	0.999972	1.46945e-2	0.990674
13	3.82764e-5	0.999971	<b>8.88908e-6</b>	<b>0.999975</b>	7.13208e-3	0.990926
14	9.36914e-5	0.999794	3.22447e-5	0.999974	1.94604e-2	0.976522
15	4.31546e-5	0.999974	2.24857e-5	0.999975	5.76271e-3	0.975872

Предвид регистрираните порядъци „ $e-2$ “ и „ $e-3$ “ на преобладаваща част от средноквадратичните грешки, използваният Scaled Conjugate Gradient approach може да бъде определен като най-малко ефективен. Съпоставяйки представените резултати най-висока степен на адекватност спрямо задачата за прогнозен анализ беше отчетена при Bayesian Regularization обучение за разглежданите случаи от входни въздействия.



**Фиг. 4.20.** Синтезирани *feed-forward* невронни модели за прогнозен анализ на трафичното натоварване на базата на BR обучение при а)  $x_1$  и  $x_2$ , б)  $x_1$  и  $x_3$ , в)  $x_2$  и  $x_3$  и г)  $x_1, x_2$  и  $x_3$

По отношение на това на фиг. 4.20 са дадени крайните синтезирани FFNN модели при 8, 10, 12 и 13 неврони в междинните слоеве за указания алгоритъм. Тук постигнатите почти еднакви нива на корелация от тестовите невронни процеси са, както следва  $R = 0.999978$  при входна комбинация “ $x_1$  and  $x_2$ ”,  $R = 0.999976$  за управляеми фактори “ $x_1$  and  $x_3$ ” и “ $x_2$  and  $x_3$ ” и  $R = 0.999975$  относно модел с наличие на три входни променливи. Регистрираните MSE в минимални граници от порядък „ $e^{-6}$ “ дават основание FFNNs да бъдат определени като инструмент за регресионно моделиране с потвърдена по-добра ефективност спрямо апарата на GRNNs.

#### 4.7. CFNN архитектури за прогнозен анализ на обслужваните потребителски заявки на сървърни станции при верига M/M/c/k при различни входни променливи LM обучение

##### 4.7.1. Обучение и подбор на CFNN архитектури за прогнозен анализ на обработвания трафик от сървърни станции при верига M/M/c/k

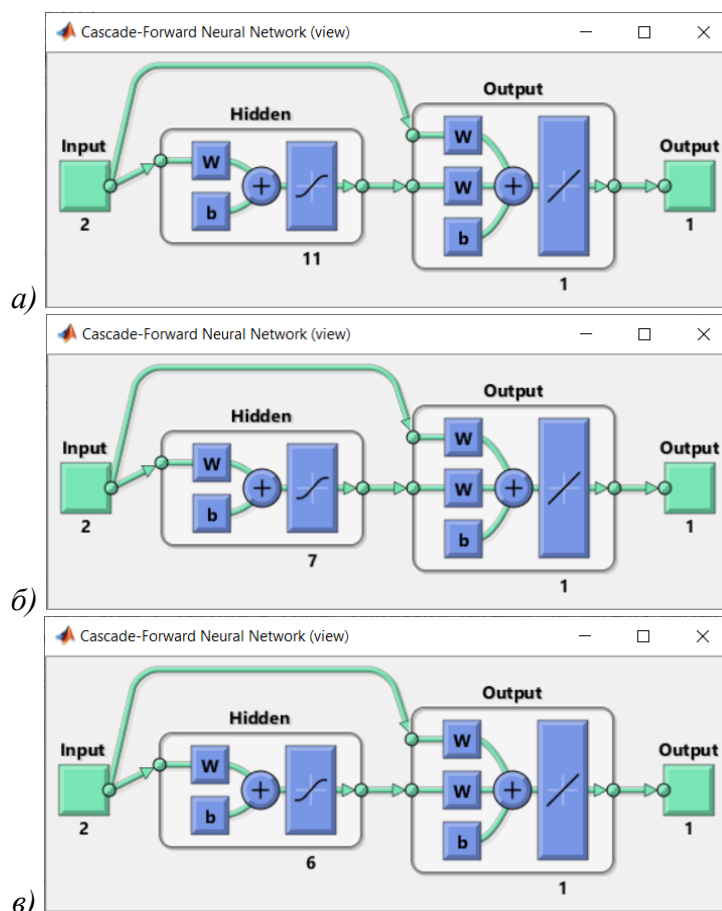
Последният етап от изследванията се отнася до прилагане на разновидност на FFNN архитектурите, при която е налице структурна връзка между входния и изходния слой или така наречените Cascade-forward Neural Networks за апроксимация относно отклик на обекта  $u_1$ . По отношение на изходния линеен слой добавянето на функционална връзка се отразява

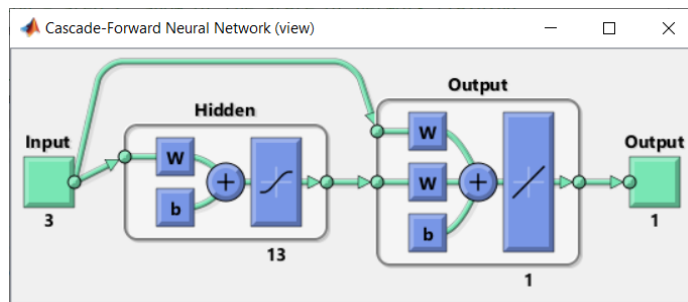
във включване на втора тегловна матрица. Във връзка с обучението на CFNN отново е използван алгоритъма на Levenberg-Marquardt при тестови модели със съдържание от 5 до 15 скрити неврони с тангенс-сигмоидална активация. Този вид невронни мрежи, както FFNNs, имат възможност за добавяне на нови междинни слоеве в зависимост от конкретното предназначение.

**Таблица 4.12.** Резултати при изследване на CFNN архитектури за прогнозен анализ при различни комбинации от входни променливи и LM обучение

Скрити неврони	MSE при $x_1$ и $x_2$	MSE при $x_1$ и $x_3$	MSE при $x_2$ и $x_3$	MSE при $x_1, x_2$ и $x_3$
5	2.8061e-05	1.3164e-05	4.8955e-05	1.0164e-05
6	1.1751e-05	1.1977e-05	<b>7.6726e-06</b>	1.6125e-05
7	2.0405e-05	<b>9.4212e-06</b>	2.0250e-05	2.2224e-05
8	9.8043e-06	1.3144e-05	1.2254e-05	1.0584e-05
9	1.8516e-05	1.4764e-05	1.0857e-05	6.1230e-05
10	1.7005e-05	2.9226e-05	1.9434e-05	1.0617e-05
11	<b>8.1190e-06</b>	1.2741e-05	1.5408e-05	3.4340e-05
12	8.3677e-06	1.4098e-05	1.9071e-05	2.1702e-05
13	2.6177e-05	2.9015e-05	3.4903e-05	<b>9.2107e-06</b>
14	1.0827e-05	9.8218e-06	2.0853e-05	2.2893e-05
15	1.0253e-05	1.8246e-05	3.7645e-05	1.3529e-05

Таблица 4.12 обобщава данни за средноквадратичната грешка във връзка с CFNNs при двойки и набор от три управляеми фактора. Обща характеристика на тестовите модели са регистрираните изменения на MSE от порядъка „e-05“.





2) **Фиг. 4.27.** Селектирани cascade-forward невронни архитектури за прогнозен анализ на обслужваните потребители при а)  $x_1$  и  $x_2$ , б)  $x_1$  и  $x_3$ , в)  $x_2$  и  $x_3$  и г)  $x_1, x_2$  и  $x_3$

За всяка анализирана комбинация от входни променливи - “ $x_1$  and  $x_2$ ”, “ $x_1$  and  $x_3$ ”, “ $x_2$  and  $x_3$ ” and “ $x_1, x_2$  and  $x_3$ ”, е избрана CFNN архитектура с най-приемливи нива съобразно изискванията за минимизация на критерия MSE, съответно  $MSE = 8.1190e-06$ ,  $MSE = 9.4212e-06$ ,  $MSE = 7.6726e-06$  и  $MSE = 9.2107e-06$ . Указните стойности на грешката са отчетени при модели с 11, 7, 6 и 13 междинни неврона, показани на фиг. 4.27.

### Изводи към четвърта глава

- ❖ Систематизиран е подход за регресионно моделиране и диагностика на аналитични и софтуерни обекти за прогнозен анализ на трафичното натоварване на обслужващи станции в имитирани информационно-комуникационни канали за връзка и трансфер на данни на основата на регресионен анализ, Generalized Regression, Feed-Forward и Cascade-Forward типове изкуствени невронни мрежи;
- ❖ Констатирана е недостатъчна степен на адекватност на регресионни архитектури за многовариантен избор на решения на база на статистически метод Дърво на решенията за прогнозен анализ на трафика поради установена необходимост от повишаване на количеството на управляемите фактори;
- ❖ Изведени са полиномиални математически регресионни модели за прогнозиране на вариациите на потенциалния количествен обслужван трафик и времената за обработка на потребителски заявки в симулационни информационно-комуникационни системи за пренос на данни;
- ❖ Синтезирани са архитектури на Generalized Regression Neural Networks за прогнозен анализ на трафичното натоварване при решаване на задача за функционална апроксимация при различни комбинации от два управляеми фактора и набор от три фактора;
- ❖ Селектирани са Feed-Forward Neural Models за прогнозен анализ на обхвата на обслужваните системни потребители на основата на обучение и подбор на мрежи с използване на Levenberg-Marquardt, Bayesian Regularization и Scaled Conjugate Gradient алгоритми на обучение;
- ❖ Създадени са Cascade-Forward невронни архитектури за прогнозен анализ на потенциалното средно трафично натоварване в имитирани информационно-комуникационни канали за връзка по Levenberg-Marquardt обучаващ алгоритъм;
- ❖ Направена е верификация на синтезираните модели въз основа на изкуствен интелект, потвърждаваща тяхната ефективност в симулационна и потенциална успешна приложимост в условия на реална среда при обработка и анализ на реален информационен трафик.

### III. ЗАКЛЮЧЕНИЕ

В дисертационния труд е предложена концепция за изпитване и измерване на въздействието на приложени сили върху метални детайли и обекти на основата на



тензорезисторни преобразуватели. Обърнато е внимание на базисни аспекти, засягащи процедурното обезпечаване на техническите възможности за:

- ❖ идентификация на типа и прогнозиране на амплитудните нива на имитирани потенциално възникнали смущения в комуникационни канали при предаване на измервателна и специфична информация в комуникационни канали за връзка в симулационна среда;
- ❖ качествен анализ по отношение на използвани комбинации от работни преобразуватели при следене на натоварвания върху тестови детайли, както и прогнозно определяне на количествените измерения на приложените сили на въздействие;
- ❖ прогнозен анализ на потенциално количество обработени потребителски заявки относно предавана измервателна сензорна информация в имитирана трафична преносна среда във връзка с планиране на капацитета от обслужван системен трафик.

По отношение на реализираните серии от изследвания могат да бъдат набелязани следните направления, надграждащи функционалността на представените системни решения и дефиниращи следващи етапи от развитие на засегнатата проблематика в дисертационния труд:

- ❖ внедряване на нови сензорни типове за следене и регистрация на приложените сили на натоварване върху изпитвани метални обекти;
- ❖ разширяване на спектъра от анализирани механични величини, които се получават като следствие от приложени набори от сили върху тестови детайли;
- ❖ подбор на методи при софтуерно проектиране, оценка на характеристиките и цялостната ефективност на IIR и FIR звена за цифрова филтрация на измервателни електрически сигнали от функционални преобразуватели;
- ❖ интеграция на методи и алгоритми на машинно обучение в хода на синтез и оценка на модели за идентификация и прогнозен анализ относно различни параметрични показатели;
- ❖ проектиране и внедряване на безжична преносна среда на база на съвременни комуникационни стандарти в областта на безжичните комуникации за пренос на сензорна информация.

#### **IV. ПРИНОСИ КЪМ ДИСЕРТАЦИОННИЯ ТРУД**

##### **Научно-приложни приноси:**

- ❖ разработена е методика за идентификация на смущаващи въздействия, анализ на тензорезисторни измервателни данни“ и прогнозиране на капацитета на обслужвания трафик при прилагане на сили върху метали с компенсирани влиянията на шумове и оптимизиране на обработваните потребителски заявки;
- ❖ селектирани са структури на изкуствени невронни мрежи с обратно разпространение на грешката на базата при Levenberg-Marquardt и Scaled Conjugate Gradient с различни активационни функции при приети показатели за качество за идентификация на Гаусов постоянен шум и Периодичен постоянен шум, както и цифрови сигнали с присъствие на посочените въздействия, в комуникационни канали за връзка;
- ❖ създадени са невронни модели при право разпространение на сигналите и обратно разпространение на грешката при различни обучаващи алгоритми за количествена идентификация на приложени работни тензорезистивни преобразуватели при следене и регистрация на сили върху метали;
- ❖ изведени са невронни структури с обратно разпространение на грешката и обобщени регресионни невронни мрежи за прогнозиране на потенциалните

приложени силови натоварвания върху тестови метални образци при процедури по механично изпитване;

- ❖ синтезирани са модели на основата на изкуствен интелект за прогнозен анализ на обслужвания трафик в имитирани информационно-комуникационни звена с помощта на Generalized Regression Neural Networks, Feed-Forward Neural Networks и Cascade-forward Neural Networks при LM, SCG и BR обучаващи алгоритми с потвърдени предимства пред класическия регресионен анализ.

#### **Приложни приноси:**

- ❖ предложена е концептуална система за изследване на характеристиките на тензорезисторни сензорни елементи при измерване на сили върху метали с въведени модули за цифрова филтрация във връзка с редуциране на шумове и дескриптивен анализ на обработваните данни;
- ❖ изведени са линейни регресионни модели при включване на един и два работни тензорезисторни преобразувателя за прогнозен анализ на изменението на приложени силови натоварвания при изпитване на метални образци;
- ❖ получени са аналитични полиномиални модели на основата на регресионен анализ за прогнозен на потенциалния обслужван трафик с пакетни измервателни и специфицирани данни с отчитане и оценка на влиянието на управляемите фактори при имитирани телекомуникационни системи.

#### **V. СПИСЪК НА ПУБЛИКАЦИИТЕ ПО ДИСЕРТАЦИЯТА**

1. Kogias P., Angelov K., **Daskalaki D.**, Sadinov S., Malamatoudis M., “Performance Analysis of High-Speed Single Channel Transmission in Optical Communication Line”. Journal of Engineering Science and Technology Review (JESTR), Special Issue on Conference in Telecommunications, Informatics, Energy and Management, Kavala Institute of Technology, pp. 94-97, ISSN: 1791-9320, E-ISSN:1791-2377, 2019. (Scopus, SJR 0.190, Q3).
2. Malamatoudis M., Kogias P., **Daskalaki D.**, Sadinov S., “Communication System for Strain Analysis Over Metals on the Base of Tensoresistor Transducers”. Advances in Intelligent Systems and Computing, 1226 AISC, pp. 321-328, 2020. ISSN: 2194-5357, (Scopus, SJR 0.184, Q4).
3. **Daskalaki D.**, “Recognition of Noise in Communication Channels by Means of Artificial Neural Networks”. International Scientific Conference Unitech 2020 November 20-21, Gabrovo, p. I-229 – I-235, ISSN: 2603-378X, 2020.
4. Balabanova I., Sadinov S., **Daskalaki D.**, Georgiev G., “Prediction of forces on metal objects by applying artificial intelligence”. 5th National Scientific Conference with International Participation TechCo’21, 2-3 July, Lovech, ISSN:2535-079X, 66-70 p., 2021.
5. Balabanova I., Sadinov S., **Daskalaki D.**, Georgiev G., „Forecasting of communication traffic load by means of artificial neural networks“. International Scientific Conference United, 19-20 November, Gabrovo, Bulgaria, volume. 1, p. I-183-188, ISSN: 2603-378X, 2021.
6. Balabanova I., Sadinov S., **Daskalaki D.**, Georgiev G., „Synthesis of Classification and Predictive FFNN Models on the Basis of Tenzoresistive Transducer Data“. AIP Publishing (Scopus), International Scientific Conference on Communications, Information, Electronic and Energy Systems – CIEES, 25 – 27 November, Ruse, pp. 1-7, 2021. In print! (IEEE Xplore, Scopus).

**TITLE: „DETECTION AND ANALYSIS THROUGH COMMUNICATION CHANNELS OF THE PHYSICAL CHARACTERISTICS OF METALS BY USING OF ULTRASONIC SENSORS“**

**Author: mag. eng. Dionisia Antimos Daskalaki**

**ABSTRACT:**

The dissertation deals with aspects related to the measurement of forces when testing the loads of parts, structures, modules and complete equipment, which are made of metal in various fields of business and industry. The concept of artificial intelligence has been introduced in approaches for qualitative and quantitative analysis of acquired measurement data from the inclusion of strain gages functional converters in classical bridge circuits for monitoring and control of power loads. One of the most important aspects in modern communications is related to the identification and assessment of superimposed unwanted random noises in the communication channels for communication in the transmission of specialized data again on the basis of artificial neural networks. An essential aspect, which is also the subject of analysis in the dissertation with integration of artificial intelligence, concerns the ability to predict the quantitative measurability of the volume of packet data served. This will ensure quality of service and optimization of the served traffic regarding the normal functioning of a specific information and communication measuring system for monitoring of power impacts, without deviations in the processes of servicing user requests.

**Keywords:** Tensoresistor transducers, Metals, Strain measurement system, Regression analysis and modeling, Noise recognition, GWN, IFN, Teletraffic system, Traffic load, Factor combinations, Artificial neural network.