

УДК 629.735(045)

О.С. Якушенко, канд. техн. наук

**НЕЙРОННІ МЕРЕЖІ ДЛЯ ДІАГНОСТУВАННЯ ГАЗОТУРБІННИХ ДВИГУНІВ**

Аерокосмічний інститут НАУ, e-mail: yuysss@mail.ru

*Розглянуто проблеми визначення архітектури нейронної мережі, оптимальної щодо якості розпізнавання класу технічного стану газотурбінного двигуна за параметрами його функціонування, формування критеріїв якості розпізнавання і створення наборів даних для навчання і тестування мережі.*

**Вступ**

Один з пріоритетних напрямів розвитку авіаційної техніки і, насамперед, авіаційних газотурбінних двигунів (ГТД) протягом останніх десятиліть – підвищення рівня контролепридатності, що, крім іншого, характеризується різким збільшенням обсягів реєстрованої інформації. Це, з одного боку, дозволяє виконувати діагностування з глибиною розпізнавання дефекту до вузла, а іноді й глибше. З другого боку, наявність великих обсягів діагностичної інформації значно ускладнює алгоритми обробки інформації, потребує високої кваліфікації експерта, збільшує час, потрібний для її аналізу та підвищує імовірність помилки. Це пов'язано із загальноприйнятим для діагностування ГТД підходом, суть якого полягає у ручному або напівавтоматизованому аналізі зміни значень діагностичних параметрів або їх відхилень у часі. Такий підхід прийнятний за наявності невеликої кількості діагностичних параметрів, але малоефективний в умовах збільшення обсягів діагностичної інформації.

**Постановка задачі**

Для зменшення навантаження експерта та підвищення якості й оперативності визначення технічного стану ГТД необхідно виконувати попередній автоматизований аналіз інформації. Результатом такого аналізу є класифікація технічного стану ГТД – віднесення двигуна до одного з класів (найпростіший випадок – до дефектних або бездефектних двигунів). Після класифікації експерт повинен проаналізувати тільки дані про дефектні двигуни.

Перспективний напрям автоматизованого визначення класу технічного стану ГТД – використання методів штучного інтелекту, коли моделюються деякі аспекти роботи мозку людини. Один із цих методів отримав назву нейронних мереж.

На сьогодні існує великий обсяг робіт, що потребують використання нейронних мереж для визначення класу технічного стану складних технічних об'єктів [1; 2]. При цьому важливим є визначення архітектури нейронної мережі. Існує багато типів нейронних мереж, що різняться між

собою будовою основних структурних елементів – нейронів та зв'язків між ними.

Від правильного вибору структури мережі значною мірою залежить якість визначення технічного стану. Тому методи та критерії вибору оптимальної структури мережі і є об'єктом цієї роботи.

**Вибір загальної архітектури нейронної мережі та методу її формування**

Розглянемо методи розпізнавання технічного стану ГТД статичними нейронними мережами, які враховують тільки поточні значення параметрів робочого процесу ГТД. Для такої класифікації найчастіше використовують так звані LVQ-мережі (Learning Vector Quantization) та мережі з прямим поширенням сигналу [3]. У праці [1] наведено характеристики якості розпізнавання класу технічного стану ГТД для LVQ-мережі.

Із цих характеристик випливає, що такі мережі мають високий рівень помилок навіть для відносно простих вхідних даних. Це зумовлює потребу використання нейронних мереж більш складної структури – багатошарових мереж з прямим поширенням сигналу.

У таких мережах нейрони об'єднуються у шари, які, у свою чергу, з'єднуються між собою послідовно. Кількість нейронів в останньому (вихідному) шарі визначається кількістю розглянутих класів. Кількість нейронів в інших шарах – величина довільна. У загальному випадку типи нейронів різних шарів та їх кількості можуть не збігатися.

Процес створення та коригування архітектури мережі досить складний і на сьогодні існують тільки загальні рекомендації. Основні етапи створення нейронної мережі:

- формування архітектури мережі (тип мережі, кількість шарів, тип нейронів у шарі);
- навчання мережі;
- оцінка адекватності навченої мережі навчальним даним;
- оцінка рівня узагальнення;
- прийняття рішення про необхідність та методи корегування мережі та навчальних даних.

Для того, щоб мережа почала працювати, її треба навчити. Для цього на вхід мережі подаються набори (вектори) діагностичних параметрів, і параметри нейронів (вагові коефіцієнти входів та зсуви) за допомогою однієї з існуючих процедур навчання змінюються таким чином, що мінімізують різницю між відгуком мережі (вектор, складений із сигналів нейронів вихідного шару) та вектором цілей навчання. Як вектор цілей можна використовувати, наприклад, набір, складений з нулів та одиниць. У цьому наборі положення одиниць презентує номер класу, до якого належить ГТД з параметрами поточного вектора вхідних даних. Довжина цього вектора дорівнює кількості класів. Ураховуючи, що для значної частини нейронів (із сигма-функцією активації) вихідний сигнал не перевищує одиницю, для кодування номера класу технічного стану замість одиниць краще використовувати значення, менше за одиницю (наприклад, 0,5...0,9).

Отже, визначення оптимальної структури нейронної мережі полягає у визначенні таких параметрів:

- кількості шарів;
- кількості нейронів у кожному шарі;
- типу функції активації нейронів кожного шару.

Крім того, необхідно визначити критерій, за яким виконується закінчення навчання мережі та критерій адекватності мережі вхідним даним. Ураховуючи вплив методу навчання мережі на результати її роботи, потрібно також вибрати метод навчання мережі, який забезпечує найкращу якість класифікації та прийнятний час, потрібний на навчання (навчання мережі може тривати декілька годин).

Як параметр адекватності мережі вхідним даним доцільно використовувати відсоток помилок розпізнавання  $\Delta$ . Для розгляду можливості одночасного виникнення дефектів у двох, або більше вузлах ГТД як характеристику адекватності можна використати відсоток грубих помилок розпізнавання  $\Delta^r$ , коли неправильно визначено усі дефекти або ГТД віднесено до класу бездефектних. Якщо мережа після навчання досить адекватно описує навчальні дані, необхідно визначити рівень узагальнення мережі – перевірити гіпотезу, що мережа добре описує не тільки дані, використані як навчальні, але й усі можливі випадки. Для цього до навченої мережі подається інший, тестовий, набір даних і оцінюється правильність його розпізнавання. Якщо оцінка адекватності отримана за цим набором, набагато гірша за отриману для навчального, можна говорити про ефект “перенавчання” мережі. У цьому

разі необхідно знов повернутися до формування архітектури мережі або змінити принципи формування навчального набору. Надалі величину  $\Delta$  ( $\Delta^r$ ), оцінену за навчальним набором, позначимо додатковим індексом Н, а отриману за контрольним – індексом К.

Як критерій закінчення навчання мережі доцільно використовувати момент виникнення ефекту перенавчання [3]. Однією з ознак перенавчання є те, що величина  $\Delta$  ( $\Delta^r$ ), оцінена за навчальним набором, продовжує знижуватися, тоді як отримана за контрольним, не змінюється або починає зростати. Тому для вибору моменту закінчення навчання, який визначається за номером циклу (епохи) і навчання, необхідно знайти момент, коли починає виконуватися умова

$$(\Delta_i^K - \Delta_i^H) - (\Delta_{i-1}^K - \Delta_{i-1}^H) > 0. \quad (1)$$

Оскільки процес навчання мережі і зміна параметрів  $\Delta$  ( $\Delta^r$ ) не жорстко детерміновані (мають стохастичну складову), доцільно закінчувати навчання у разі виконання умови (1) протягом 2–3 циклів поспіль.

Тип нейронів та їх кількість у шарах, а також кількість шарів визначаються, виходячи з вимоги забезпечення мережею після навчання найнижчого або заданого рівня величини  $\Delta$  ( $\Delta^r$ ).

Найчастіше як структурні елементи мережі прямим поширенням сигналу використовуються нейрони з функціями активації таких типів, як перцептронна, лінійна, сигмоїдні (гіперболічний тангенс, логістична). Як приклад схему нейронної мережі з нейронами, що мають логістичну функцію активації, показано на рис. 1.




Рис. 1. Схема тришарової нейронної мережі з прямим поширенням сигналу

Мережу призначено для класифікації 16 класів технічного стану (16 вихідних нейронів). Вона має 7 і 28 нейронів у першому та другому шарах. Набір вхідних даних складається із семи-компонентних векторів. Нейрони усіх шарів мають логістичну функцію активації.

Очевидно, що нейрони перцептронного типу, оскільки на їх виході сигнал може набувати значення 0 або 1, і можуть бути використані, в першу чергу, у вихідному конкуруючому шарі [3]. Але з погляду зменшення обсягу мережі і відповідно витрати часу і ресурсів комп'ютера доцільніше отримувати на виході мережі вектора не булеві, а неперервні відгуки. У цьому разі клас технічного стану ГТД визначають за номе-

ром виходу, відгук на якому найбільший. Тому надалі розглянемо мережу з лінійними та сигмоїдними нейронами.

### Формування набору даних для навчання нейронної мережі

У праці [1] наведено приклад створення LVQ-мережі. При цьому використано набори даних, що описують випадок, коли класи технічного стану ГТД у просторі ознак стану (діагностичних відхилень) дуже рознесені, а функцію  $\hat{f}(\bullet)$  (див. залежність (2) у праці [1]) прийнято нормальною, що забезпечує мале подання членів класів у примежовій смузі між класами.

Більш складний для розпізнавання випадок, коли  $\hat{f}(\bullet)$  має рівномірний закон розподілу, за якого у примежовій смузі розміщено більше представників різних класів. Таке подання більш адекватно описує випадок поступової деградації ГТД.

Адекватне розділення вхідних даних за допомогою мережі для цього випадку значно ускладнюється.

Крім того, використані в праці [1] набори містять тільки основні класи технічного стану (основний клас описує випадок зміни функціональних характеристик тільки одного елемента проточної частини).

Для нормальної роботи мережа мусить розпізнавати не тільки основні але й, принаймні, вторинні класи, які являють собою попарну комбінацію основних класів (подвійні дефекти). Як приклад у табл. 1 наведено характеристики можливих первинних та вторинних класів для двигуна ПС-90А [4].

Характеристику наведених у табл. 1 параметрів стану ( $a_{GB}$ ,  $a_{GKB}$  та ін.) викладено у праці [5], метод формування наборів даних, у т. ч. й опис параметрів  $\Delta a_i^{\min}$ ,  $\overline{\Delta a_i^{\min}}$ ,  $\overline{\Delta a_i^A}$  – у праці [1].

Дані про зміну значень нормованих діагностичних відхилень у розрахункових точках навчального набору показано на рис. 2 і 3, де частота обертання ротора високого тиску позначена  $n_{BT}$ , повний тиск за вентилятором –  $P_B^*$ , повний тиском за компресором –  $P_K^*$ , повна температура за компресором –  $T_K^*$ , повна температура за турбіною –  $T_T^*$ , відношення повного тиску за турбіною до тиску на вході ГТД –  $P_T^*/P_{BX}$ , витрата палива –  $\overline{G_{II}}$ .

Таблиця 1

### Характеристика класів технічного стану ГТД

Номер класу	Вузол, що деградував	Основний параметр стану математичної моделі ГТД / максимальне відхилення	Допоміжний параметр стану математичної моделі ГТД / максимальне відхилення
Первинні класи			
1.	Нема дефекту (справний ГТД)	$a_{GB}/0,1$ $a_{GKB}/0,1$ $a_{EG}/0,1$ $a_{ATB}/0,07$ $a_{ATH}/0,07$	$a_{EB3}/0,1$ $a_{EKB}/0,1$ $a_{K3}/0,1$ $a_{ETB}/0,07$ $a_{ETH}/0,07$
2.	Вентилятор (зовнішній контур)	$a_{GB} / 0,1$	$a_{EB3} / 0,1$
3.	Компресор високого тиску	$a_{GKB} / 0,1$	$a_{EKB} / 0,1$
4.	Камера згоряння	$a_{EG} / 0,1$	$a_{K3} / 0,1$
5.	Турбіна високого тиску	$a_{ATB} / 0,07$	$a_{ETB} / 0,07$
6.	Турбіна низького тиску	$a_{ATH} / 0,07$	$a_{ETH} / 0,07$
Вторинні класи (комбінації первинних)			
7.	2 + 3	$a_{GB} / 0,1$ $a_{GKB} / 0,1$	$a_{EB3} / 0,1$ $a_{EKB} / 0,1$
8.	2 + 4	$a_{GB} / 0,1$ $a_{EG} / 0,1$	$a_{EB3} / 0,1$ $a_{K3} / 0,1$
9.	2 + 5	$a_{GB} / 0,1$ $a_{ATB} / 0,07$	$a_{EB3} / 0,1$ $a_{ETB} / 0,07$
10.	2 + 6	$a_{GB} / 0,1$ $a_{ATH} / 0,07$	$a_{EB3} / 0,1$ $a_{ETH} / 0,07$
11.	3 + 4	$a_{GKB} / 0,1$ $a_{EG} / 0,1$	$a_{EKB} / 0,1$ $a_{K3} / 0,1$
12.	3 + 5	$a_{GKB} / 0,1$ $a_{ATB} / 0,07$	$a_{EKB} / 0,1$ $a_{ETB} / 0,07$
13.	3 + 6	$a_{GKB} / 0,1$ $a_{ATH} / 0,07$	$a_{EKB} / 0,1$ $a_{ETH} / 0,07$
14.	4 + 5	$a_{EG} / 0,1$ $a_{ATB} / 0,07$	$a_{K3} / 0,1$ $a_{ETB} / 0,07$
15.	4 + 6	$a_{EG} / 0,1$ $a_{ATH} / 0,07$	$a_{K3} / 0,1$ $a_{ETH} / 0,07$
16.	5 + 6	$a_{ATB} / 0,07$ $a_{ATH} / 0,07$	$a_{ETB} / 0,07$ $a_{ETH} / 0,07$

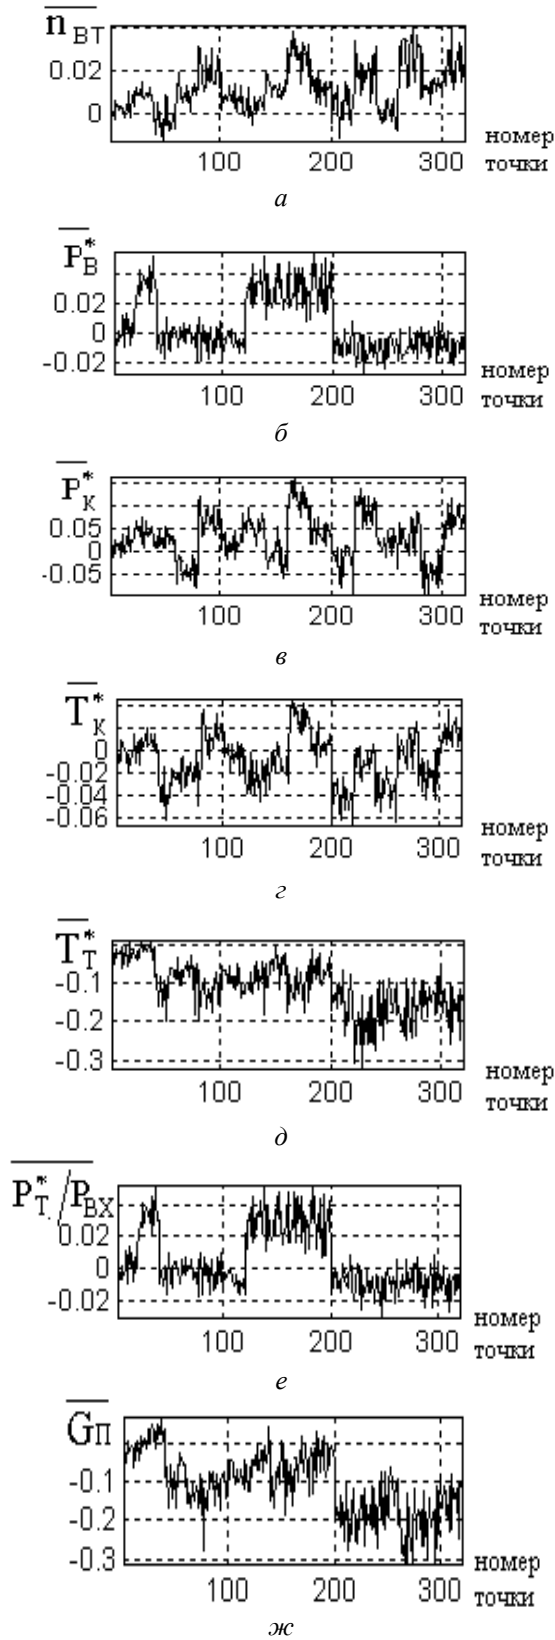


Рис. 2. Зміна значень діагностичних нормованих відхилень у навчальній вибірці, призначеній для навчання мережі розпізнаванню 16 класів технічного стану:

$a - \overline{n_{BT}}$  ;  $b - \overline{P_B^*}$  ;  $v - \overline{P_K^*}$  ;  $z - \overline{T_K^*}$  ;  $d - \overline{T_T^*}$  ;  $e - \overline{P_T^*/P_{BX}}$  ;  $ж - \overline{G_{\Pi}}$

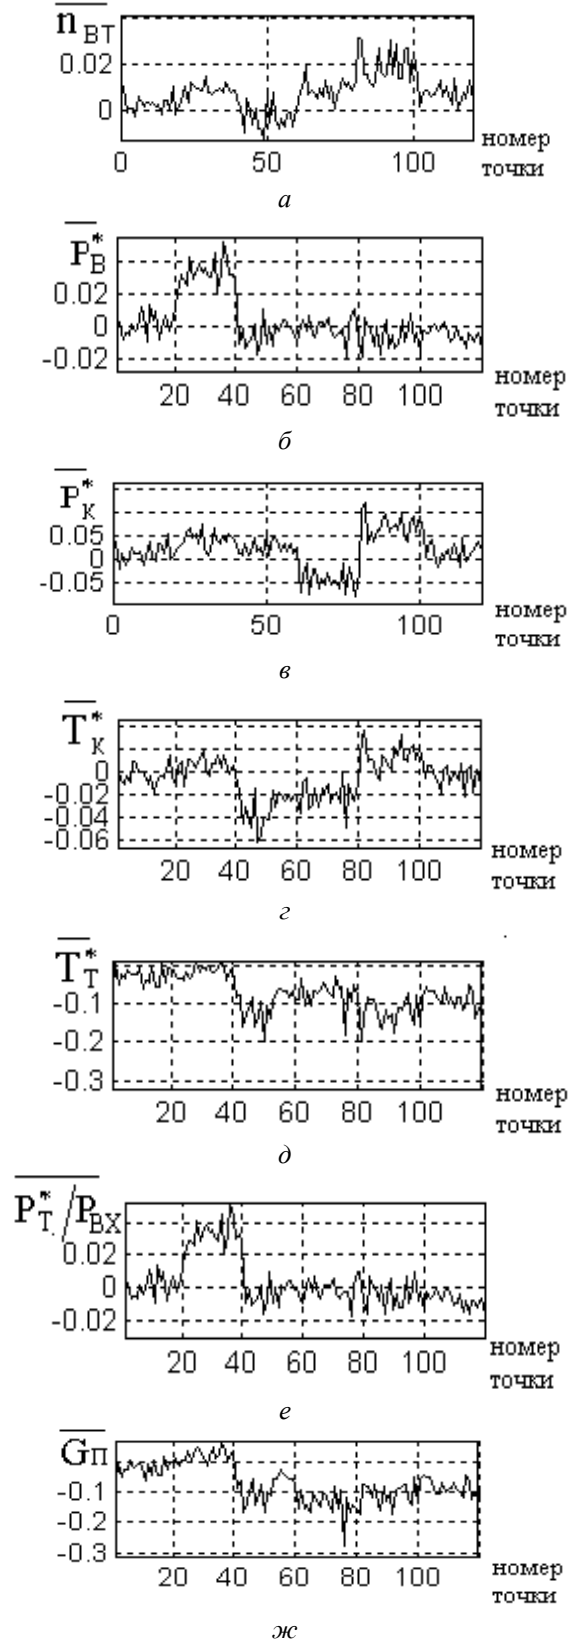


Рис. 3. Збільшена ділянка основних (одиничних) класів навчальної вибірки, наведеної на рис. 2:

$a - \overline{n_{BT}}$  ;  $b - \overline{P_B^*}$  ;  $v - \overline{P_K^*}$  ;  $z - \overline{T_K^*}$  ;  $d - \overline{T_T^*}$  ;  $e - \overline{P_T^*/P_{BX}}$  ;  $ж - \overline{G_{\Pi}}$

У наведеному наборі кожен клас подано 20 точками. Для розрахунку брали  $\overline{\Delta a_i^A} = 0,4$ , діапазон  $\overline{\Delta a_i^{\min}} \dots \overline{\Delta a_i^{\max}}$  для бездефектного двигуна –  $0,1 \dots \overline{\Delta a_i^A}$ , для дефектних –  $\overline{\Delta a_i^A} \dots 1$ .

За даними рис. 3 виконано якісний аналіз можливості розпізнавання основних дефектних класів. Проаналізовано напрям та ступінь зміщення відносно діагностичних відхилень бездефектного класу (точки 1–20), відхилень 2–6 класів (точки 21–120). Результати аналізу наведено у табл. 2. Як можна бачити усі основні класи досить добре розподілені у просторі ознак стану (діагностичних відхилень).

Таблиця 2

**Напрямок та ступінь зміщення відхилень параметрів дефектних двигунів відносно відхилень, що відповідають справному класу**

Номер класу	Напрямок зміщення відхилення						
	1	2	3	4	5	6	7
2	↑	↑↑	↑	0	0	↑↑	↑
3	↓	0	0	↓	↓↓	0	↓
4	↑	0	↓↓	↓	↓	0	↓↓
5	↑↑	0	↑↑	↑	↓	0	↓↓
6	0	0	0	0	↓	0	↓↓

Наведений на рис. 2 і 3 набір призначено для попереднього оцінювання характеристик мережі. Для кінцевого уточнення архітектури та отримання працездатності мережі необхідно мати суттєво більший набір. Тому було згенеровано навчальний та тестовий набори, кожен з яких був у 10 разів більшим, ніж показаний на рис. 2 і складався з 3200 точок. В іншому алгоритмі отримання набору не змінився.

Тестові набори даних отримано аналогічним чином за іншими початковими параметрами генератора псевдовипадкових чисел [6].

## Висновки

Визначено загальну архітектуру статичної нейронної мережі, призначеної для розпізнавання класу технічного стану ГТД. Виконано постановку задачі створення оптимальної щодо якості класифікації, мережі та розроблено метод вирішення поставленого завдання. Отримано набір даних, призначений для навчання та тестування статичної нейронної мережі розпізнаванню одиночних та подвійних дефектів елементів проточної частини ГТД.

## Список літератури

1. Кучер О.Г., Якушенко О.С., Сухоруков В.Ю. Розпізнавання технічного стану авіаційних ГТД з використанням нейронних мереж. – Запоріжжя: ЗНТУ; ХАІ; МоторСіч, 2002. – №1. – С. 101–106.
2. Адаменко В.А., Дубровин В.И., Субботин С.А. Диагностика лопаток авиадвигателей по спектрам затухающих колебаний после ударного возбуждения на основе нейронных сетей прямого распространения // Новые материалы и технологии в металлургии та машинобудуванні. – 2000. – № 1. – С. 91–96.
3. Медведев В.С., Потемкин В.Г. Нейронные сети. MatLab 6 / Под общ. ред. В.Г.Потемкина. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.
4. Двигатель ПС-90А. Руководство по технической эксплуатации. В 3-х кн. – Пермь: ПНПО “Авиадвигатель”, 1990.
5. Игнатович С.Р., Якушенко А.С. Использование математической модели рабочего процесса ГТД при прогнозировании его остаточного ресурса // Прогресс – технология – качество: Тр. II Конгресса двигателестроителей Украины. – Харьков: ИМиС, 1997. – С. 279–281.
6. Арсак Ж. Программирование игр и головоломок: Пер. с франц. – М.: Наука. Гл.ред.физ.-мат.лит., 1990. – 224 с.

Стаття надійшла до редакції 18.12.03.

А.С. Якушенко

Нейронные сети для диагностирования газотурбинных двигателей

Рассмотрены проблемы определения архитектуры нейронной сети, оптимальной с точки зрения качества распознавания класса технического состояния газотурбинного двигателя по параметрам его функционирования и формирования критериев качества распознавания и создания наборов данных для обучения и тестирования сети.

A.S. Yakushenko

Neural networks for gas turbine engine diagnosing

Problems of a neural networks architecture definition, which is optimal one for effective gas turbine engine technical state class recognition by parameters of working process, are considered in article. The question of formation of recognition quality criteria and creation of data sets for the network training and testing are considered too.