

Научная статья

УДК 004.032.26:58

DOI 10.35266/1999-7604-2024-2-3



КЛАССИФИКАЦИЯ СОСТОЯНИЯ РАСТЕНИЙ С ИСПОЛЬЗОВАНИЕМ АДАПТИВНОЙ НЕЙРО-НЕЧЕТКОЙ ИНФЕРЕНЦИОННОЙ СИСТЕМЫ (ANFIS)

Валентин Валерьевич Брыкин¹✉, Михаил Яковлевич Брагинский²,
Дмитрий Викторович Тараканов³, Инесса Леонидовна Назарова⁴

^{1, 2, 3, 4}Сургутский государственный университет, Сургут, Россия

¹valentin.brykin@mail.ru✉, <https://orcid.org/0000-0002-6143-8992>

²braginskiy_my@surgu.ru, <https://orcid.org/0000-0003-1332-463X>

³sprtdv@mail.ru, <https://orcid.org/0000-0003-1851-1039>

⁴nazarova_il@surgu.ru, <https://orcid.org/0009-0001-0340-2609>

Аннотация. В данной работе используется адаптивная нейро-нечеткая система ANFIS для классификации восьми болезней растений. В качестве входных данных системы применяются текстурные признаки Харалика, извлеченные из изображений растений. Обучение ANFIS проводилось с использованием гибридного алгоритма, сочетающего обратное распространение ошибки и градиентный спуск. Эффективность ANFIS оценивалась на тестовом наборе посредством вычисления точности, полноты и F1-меры. Полученные показатели подлежали сравнению с другими современными средствами классификации.

Ключевые слова: текстурные признаки Харалика, нейронная сеть, нейро-нечеткая система, логистическая регрессия, классификация цифровых изображений

Для цитирования: Брыкин В. В., Брагинский М. Я., Тараканов Д. В., Назарова И. Л. Классификация состояния растений с использованием адаптивной нейро-нечеткой инференционной системы (ANFIS) // Вестник кибернетики. 2024. Т. 23, № 2. С. 23–30. DOI 10.35266/1999-7604-2024-2-3.

Original article

CLASSIFYING PLANTS' HEALTH USING AN ADAPTIVE NEURO-FUZZY INFERENCE SYSTEM (ANFIS)

Valentin V. Brykin¹✉, Mikhail Ya. Braginsky², Dmitry V. Tarakanov³, Inessa L. Nazarova⁴

^{1, 2, 3, 4}Surgut State University, Surgut, Russia

¹valentin.brykin@mail.ru✉, <https://orcid.org/0000-0002-6143-8992>

²braginskiy_my@surgu.ru, <https://orcid.org/0000-0003-1332-463X>

³sprtdv@mail.ru, <https://orcid.org/0000-0003-1851-1039>

⁴nazarova_il@surgu.ru, <https://orcid.org/0009-0001-0340-2609>

Abstract. The study classifies eight types of plants' diseases using an adaptive neuro-fuzzy inference system (ANFIS). Haralick texture features obtained from plants' images are applied as input data for a system. A hybrid algorithm consisting of a backward propagation of error and a gradient descent performed the ANFIS training. The ANFIS efficiency was assessed on a test set through calculating accuracy, comprehensiveness, and the F1 score. The indicators obtained by this method were compared with other modern classification methods.

Keywords: Haralick texture features, neural network, neural fuzzy system, logistic regression, classification of digital images

For citation: Brykin V. V., Braginsky M. Ya., Tarakanov D. V., Nazarova I. L. Classifying plants' health using an adaptive neuro-fuzzy inference system (ANFIS). *Proceedings in Cybernetics*. 2024;23(2):23–30. DOI 10.35266/1999-7604-2024-2-3.

ВВЕДЕНИЕ

Сегодня цифровизация сельского хозяйства, где полевые условия контролируются с помощью автономных систем, набирает все большие обороты. При создании систем подобного рода необходимо решать задачи идентификации болезни растений, анализировать динамику их роста.

Задача выявления болезней растений, недостаток воды, микроэлементов на всех стадиях развития позволяет минимизировать экономические потери в агробизнесе. Таким образом, для решения вышеуказанной задачи необходимо использовать методы дистанционного мониторинга состояния растений, способных выявлять болезни растений с высокой точностью и скоростью.

Имеется большая потребность в новых технологиях, отслеживающих рост растений и прогнозирующих воздействие на него различных факторов. В большинстве случаев болезни можно проследить по состоянию побегов растения (стебля, листьев). Значит, идентификация растений, выявление болезней, анализ роста играют существенную роль в успешном выращивании агрономических культур.

Все операции, связанные с обработкой изображений, выполняются в цветовом пространстве RGB, являющемся одним из основных способов представления изображений.

МАТЕРИАЛЫ И МЕТОДЫ

Текстурные признаки Харалика

Текстура наряду с цветом является самой важной особенностью, если необходимо обнаружить какой-либо объект. Это относится и к классификации состояния растений – любое заболевание отличается характерным распространением по организму и цветом. На основе расположения пикселей на изображении появляется возможность идентифицировать любой объект.

Существует множество способов текстурного анализа. Здесь используется метод текстурных признаков Харалика. Эти признаки рассчитываются на основе матрицы совпадения уровней серого (gray-level co-occurrence matrix, GLCM), являющейся оценкой плот-

ности распределения вероятностей второго порядка $p_2(P, Q, Z, Y)$, полученной по одному изображению в предположении, что плотность вероятности p_2 зависит лишь от взаимного расположения P и Q . При этом Z является числом, обозначающим учет соседних пикселей, в том числе их расстояния от пикселя интереса. Y – значение ориентации пикселя интереса и соседних пикселей (в градусах) в интервале $[0; 2\pi)$ с шагом $\pi/4$.

GLCM-матрица представляет собой текстурные свойства, но она неудобна при непосредственном анализе изображения [1–5]. Признаки Харалика, вычисляемые на ее основе, зарекомендовали себя куда лучше. В данной работе использовались 4 информативных признака, дающих наибольшую итоговую точность, из 14 возможных:

Контраст. Измеряет пространственную частоту изображения.

$$con = \sum_{i=1}^N \sum_{j=1}^N p_{ij} (i - j)^2. \quad (1)$$

Несходство. Мера расстояния между парами пикселей в интересующей области.

$$dis = \sum_{i=1}^N \sum_{j=1}^N |i - j| \times p(i, j)^2. \quad (2)$$

Энергия (второй угловой момент). Измеряет текстурную однородность изображения.

$$enr = \sum_{i=1}^N \sum_{j=1}^N p(i, j)^2. \quad (3)$$

Однородность (обратный разностный момент). Измеряет однородность изображения, которая возрастает при уменьшении тона серого.

$$hom = \sum_{i=1}^N \sum_{j=1}^N \frac{p(i, j)}{1 + (i - j)^2}. \quad (4)$$

Система ANFIS

Адаптивная нейро-нечеткая инференционная система (ANFIS) – это гибридная интеллектуальная система, которая сочетает в себе принципы нечеткой логики и нейронных сетей. Она была разработана в 1993 г. Дж. С.Р. Янгом. ANFIS может быть использована для моделирования сложных нелинейных систем, классификации и прогнозирования [6–9].

Структура ANFIS обычно состоит из пяти слоев (рис. 1).

– Входной слой (Layer 1): получает входные данные и преобразует их в степени принадлежности к функциям принадлежности. В качестве такой функции используют, например, функцию Гаусса.

$$O_i^1 = \mu A_i(x_i) = e^{-\frac{1}{2}(\frac{x_i - c_i}{\sigma_i})^2}, \quad (5)$$

где c – центр функции принадлежности;

σ – ширина функции принадлежности.

– Слой нечеткого вывода (Layer 2): вычисляет веса правил на основе степеней принадлежности входных данных.

$$O_i^2 = W_i = \mu A_1(x_1) * \mu A_2(x_2) * ... * \mu A_i(x_i), \quad (6)$$

где W_i – вес i -го правила;

$\mu A_i(x_i)$ – степень принадлежности входного значения x_i функции принадлежности A_i .

– Нормализующий слой (Layer 3): нормализует веса правил.

$$O_i^3 = \bar{W}_i = \frac{W_i}{\sum_{i=1}^n W_i}. \quad (7)$$

– Слой дефаззификации (Layer 4): вычисляет произведение нормализованного правила на выходную функцию.

$$O_i^4 = \bar{W}_i * f_i = \bar{W}_i * (+ p_i x_1 + q_i x_2 + ... + r_i), \quad (8)$$

где $\bar{W}$ – результат уровня 3;

f_i – выходное значение i -го правила;

(p_i, q_i, r_i) – набор параметров следствия узла i .

– Слой вывода (Layer 5): вычисляет взвешенную сумму выходов всех правил.

$$O_i^5 = \sum_{i=1}^n \bar{W}_i * f_i = \frac{\sum_{i=1}^n W_i * f_i}{\sum_{i=1}^n W_i}. \quad (9)$$

Алгоритм классификации

Определения текущего состояния растения основано на решении задачи классификации цифровых изображений на основе анализа текстуры и цвета. Алгоритм классификации основан на совместном применении текстурных признаков Харалика и современных инструментов классификации.

Схема алгоритма представлена на рис. 2.




Рис. 1. Структура ANFIS

Примечание: составлено авторами.




Рис. 2. Схема алгоритма классификации

Примечание: составлено авторами.

Как можно увидеть из рис. 2, после инициализации набора данных и его предварительной обработки из каждого изображения извлекаются текстурные признаки, которые передаются в качестве входных данных для классификационных методов.

Загрузка и подготовка данных

Исходные данные приведены на рис. 3 и представляют собой набор цветных цифровых изображений, распределенных по директориям, имена которых соответствуют названиям классов. Изображения были предварительно подготовлены – приведены к единому размеру 256×256 пикселей и распределены поровну на каждый класс (сбалансированы по 2200 единиц в каждом классе, суммарно 17600 фотографий). Таким образом, количество директорий совпадает с числом классов, равным 8.

Датасет на рис. 3 был загружен с общедоступного ресурса по исследованию данных Kaggle.

Извлечение признаков

Так как исходное изображение представляет собой RGB-область размером 128×128 пикселей исходного изображения, для каждого из трех его каналов (красная, зеленая и синяя компоненты) строится симметричная нормированная GLCM-матрица в 256 оттенках серого. Значит, для целого изображения будет вычислено 3 GLCM-матрицы оттенков серого. В свою очередь, каждая такая матрица порождает 4 значения признаков Харалика, описанных ранее. Таким образом, одно цветное изображение бу-

дет описано вектором-строкой из 12 коэффициентов-признаков Харалика.

Для удобства восприятия и дальнейших расчетов все коэффициенты – а это массив размером $m \times k$ (где $m = 17\,600$ – общее число изображений в наборе данных, $k = 12 + 1 = 13$ – итоговое количество признаков Харалика и метка класса, закодированная способом «label encoding») – были записаны в CSV-файл средствами библиотеки Pandas языка Python (рис. 4).

Стоит также упомянуть другие модули и библиотеки Python, задействованные в данной работе:

Os – для работы с операционной и файловой системами (загрузка и инициализация набора данных);

OpenCV – для анализа изображений;

NumPy – для работы с многомерными массивами;

Matplotlib – для визуализации данных и вычислений;

Anfis – для нечетких вычислений;

Scikit-Learn – для операций машинного обучения.

Предварительная обработка данных

Фактически датафрейм из рис. 5 представляет собой готовую для дальнейших вычислений и решения основной задачи базу данных признаков изображений. Входными данными для обучения нейронной сети будут являться значения признаков Харалика (все столбцы датафрейма, кроме последнего), выходными – последний столбец датафрейма с закодированными метками классов.



Рис. 3. Классы исходных данных
Примечание: составлено авторами.

features_db								
	0	1	2	3	4	5	6	...
0	1553.198120	2060.362946	1171.758636	1393.249298	0.076277	0.076546	0.076015	...
1	1490.319397	1115.246582	1598.354919	2341.404175	0.090693	0.090494	0.086959	...
2	2588.799622	5389.672791	2168.333527	1171.598816	0.233439	0.234230	0.228993	...
3	1630.973450	1723.165375	1520.119598	2698.978638	0.092927	0.092899	0.091825	...
4	1620.140015	1768.595612	1494.767761	2675.156372	0.091095	0.091131	0.090237	...
...	...	...	...	...	...	...	...	...
17595	3346.186890	3439.760468	693.740204	844.401672	0.215740	0.216874	0.206939	...
17596	1638.140228	2546.195953	436.153076	1110.063110	0.471450	0.473478	0.457407	...
17597	811.761047	2261.653107	458.613220	1446.747620	0.235745	0.235558	0.230777	...
17598	1385.866791	1878.329651	1318.927338	1372.675537	0.064252	0.064139	0.063280	...
17599	1659.912781	3139.970367	585.401855	717.408020	0.347553	0.348532	0.339566	...

17600 rows × 13 columns

Рис. 4. Текстуры признаки Харалика для исходного датасета

Примечание: составлено авторами.

```
# Разделение данных на обучающий и проверочный наборы
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)

# Применение кластеризации FCM для инициализации функций принадлежности
fcm = FuzzyCMeans(n_clusters=8)
fcm.fit(X_train)

# Создание функций принадлежности ANFIS на основе кластеров FCM
num_features = X_train.shape[1]
input_mf = []
for i in range(num_features):
    centers = fcm.cluster_centers[:, i]
    stds = np.std(X_train[:, i])
    for j in range(3): # 3 функции принадлежности для каждого признака
        input_mf.append({'name': f'feat{i}_mf{j}', 'mftype': 'gaussmf', 'params': [centers[j], stds]})

# Создание модели ANFIS и ее обучение
anfis_model = anfis.ANFIS([input_mf], 8, 4)
anfis_model.train(X_train, y_train, epochs=1000, batch_size=20)

# Оценка модели на проверочном наборе
y_pred = anfis_model.predict(X_test)
accuracy = np.mean(y_pred == y_test)
print('Точность:', accuracy)
```

Рис. 5. Создание и обучение ANFIS

Примечание: составлено авторами.

Следующим шагом является предварительная обработка данных.

Во-первых, это разделение на обучающую и тестовую выборки в оптимальном соотношении 70:30.

Во-вторых, стандартизация: некоторые характеристики имеют широкий диапазон значений и в процессе классификации могут создать систематическую ошибку. Вспомогательный класс `StandardScaler` масштабирует

данные так, чтобы они имели нулевое среднее значение и единичную дисперсию ($\mu = 0$, $\sigma = 1$). Важно то, что здесь выполняется стандартизация лишь входных данных, поскольку выходные содержат только закодированные метки [5, 6].

Моделирование ANFIS

Создание модели ANFIS для восьмиклассовой классификации с 12 входными признаками Харалика состоит из следующих шагов.

Подготовка данных

- Собирается набор данных (изображений), помеченных 8 классами.
- Извлекается 12 признаков Харалика из каждого изображения (по 4 из каждой компоненты R, G, B).

- Набор данных разделяется на обучающий и проверочный наборы.

Создание функции принадлежности

- Выбирается тип функций принадлежности (в данном случае – гауссова).
- Определяется количество и местоположение функций принадлежности для каждого входного признака (далее для каждого признака используется 3 функции принадлежности).

Для инициализации начальных параметров функций принадлежности, таких как центры и стандартные отклонения, в данной работе используется метод нечеткой кластеризации С-средних. Это помогает избежать ручной настройки параметров и обеспечивает более точную и эффективную классификацию.

Расчет степеней принадлежности

- Для каждого обучающего и тестового изображения вычисляется степень принадлежности каждого признака каждой функции принадлежности.

Создание правил

В моделях ANFIS используется нечеткое правило Такаги–Сугено–Канга (TSK). Правила TSK имеют следующую форму:

Если x_1 относится к A_1 и x_2 относится к A_2 и ... и x_n относится к A_n ,
то $y = f(x_1, x_2, \dots, x_n)$.

Количество правил TSK рассчитывается по следующему выражению:

$$\text{Количество правил} = (\text{Количество функций принадлежности для признака } 1) \wedge \dots \wedge (\text{Количество признаков}),$$

где *Количество функций принадлежности для признака 1* – это количество функций принадлежности, используемых для представления первого признака;

Количество признаков – это количество входных признаков в модели ANFIS.

Во избежание усложнения работы модели и увеличения числа правил TSK целесообразно сократить количество входных признаков: для каждого изображения будет взято среднее значение признака Харалика по каналам, например, для контраста:

$$\text{con}_{mean} = \frac{\text{con}_R + \text{con}_G + \text{con}_B}{3}. \quad (10)$$

Таким образом, число входных признаков сократится до 4, а значит количество правил TSK в модели ANFIS для классификации изображений на 8 классов будет равно $3^4 = 81$. Каждая комбинация функций принадлежности соответствует одному правилу TSK.

Модель ANFIS обучается с использованием гибридного алгоритма, который сочетает градиентный спуск и метод наименьших квадратов.

Алгоритм обучения состоит из двух основных этапов.

Прямой проход:

- Для каждого обучающего образца вычисляются степени принадлежности каждой функции принадлежности.

- Вычисляются веса правил TSK, используя степени принадлежности в качестве весов. Для вычисления весов правил используется метод наименьших квадратов. Это гарантирует, что взвешенная сумма выходных значений правил наиболее точно соответствует целевому выходному значению.

- Вычисляется взвешенная сумма выходных значений правил, чтобы получить прогнозируемое выходное значение модели.

- Вычисляется ошибка между прогнозируемым и фактическим выходным значением.

Обратный проход:

– Ошибка распространяется назад через сеть, чтобы обновить параметры функций принадлежности и веса правил.

– Параметры функций принадлежности и веса правил настраиваются с использованием градиентного спуска, чтобы минимизировать ошибку.

На этапе обратного прохода для настройки параметров функций принадлежности и весов правил используется градиентный спуск. Градиент ошибки рассчитывается относительно этих параметров, и они обновляются в направлении, который минимизирует ошибку.

Прямой и обратный проходы повторяются до тех пор, пока не будет достигнуто заданное количество эпох или пока ошибка не будет сведена к минимуму.

Таким образом, модель ANFIS для решения текущей задачи имеет следующие параметры:

- Количество входов: 4
- Количество выходов: 8 (1 общий)
- Количество функций принадлежности для каждого признака: 3
- Количество правил: 81
- Веса инициализируются случайными значениями и обучаются с помощью обратного распространения.

Код инициализации и обучения модели представлен на рис. 5.

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Непосредственно классификация, помимо модели ANFIS, выполнялась еще тремя инструментами:

– сверточной архитектурой нейронной сети (CNN, MobileNetV2);

– классическим алгоритмом машинного обучения – логистической регрессией;

– базовой моделью искусственной нейронной сети – персептроном (ANN).

Результаты приведены в сравнительной таблице.

Как можно видеть из таблицы, CNN на базе MobileNetV2, использующей глубинно-разделимую свертку, справляется с задачей лучше прочих инструментов классификации, но ANFIS имеет перспективы улучшения – оптимизации параметров, в частности интеграции с генетическим алгоритмом или методами кластеризации.

ЗАКЛЮЧЕНИЕ

Полученные результаты показывают, что ANFIS может эффективно классифицировать болезни растений с высокой точностью. Использование текстурных признаков Харалика в качестве входных параметров оказалось полезным для различения болезней растений. Гибридный алгоритм обучения обеспечил быструю сходимость и хорошую точность.

Несмотря на то что CNN на основе MobileNetV2 лучше справилась с задачей, ANFIS является перспективным инструментом для классификации болезней растений. Дальнейшие исследования могут быть направлены на расширение набора данных, исследование других признаков и оптимизацию архитектуры ANFIS для улучшения производительности, в частности целесообразно интегрировать в модель генетический алгоритм.

Таблица

Результаты классификации

Метод классификации	Метрика			
	accuracy	precision	recall	f-score
ANFIS	85 %	0,85	0,84	0,84
CNN (MobileNetV2)	93 %	0,92	0,93	0,92
Логистическая регрессия	84 %	0,84	0,83	0,84
ANN	82 %	0,82	0,83	0,82

Примечание: составлено авторами.

Список источников

1. Гурлина Е. В. Разработка метода выявления текстурных свойств заданных классов изображений с использованием признаков Харалика // Перспективные информационные технологии (ПИТ 2020) : труды Междунар. науч.-технич. конф., 21–22 апреля 2020 г., г. Самара. Самара : Самарский научный центр РАН, 2020. С. 112–116.
2. Lofstedt T., Brynolfsson P., Asklund T. Gray-level invariant Haralick texture features // PLoS ONE. 2019. Vol. 14, no. 2. P. e0212110.
3. Брыкин В. В., Брагинский М. Я., Тараканов Д. В. и др. Классификация состояния растений средствами текстурного вейвлет-анализа и машинного обучения // Вестник кибернетики. 2024. Т. 23, № 1. С. 23–30. DOI 10.35266/1999-7604-2024-1-3.
4. Vyas A., Paik J. Review of the application of wavelet theory to image processing // IEIE Transactions on Smart Processing & Computing. 2016. Vol. 5, no. 6. P. 403–417. DOI 10.5573/IEIESPC.2016.5.6.403.
5. Балаганский А. Ю., Гребеньков А. А. Вейвлет-преобразование для обработки изображений системы управления отоплением с применением методов машинного обучения // Информация и образование: границы коммуникаций. 2022. № 14. С. 147–150.
6. Mahajan V., Dhumale N. R. Leaf disease detection using fuzzy logic // International Journal of Innovative Research in Science, Engineering and Technology. 2018. Vol. 7, no 6. P. 6801–6807. DOI 10.15680/IJIR-SET.2018.0706067.
7. Ashish P., Tanuja P. Survey on detection and classification of plant leaf disease in agriculture environment // International Advanced Research Journal in Science, Engineering and Technology. 2017. Vol. 4, no. 4. P. 137–139. DOI 10.17148/iarjset/nciarcse.2017.40.
8. Thyagarajan K. K., Kiruba Raji I. A review of visual descriptors and classification techniques used in leaf species identification // Archives of Computational Methods in Engineering. 2019. Vol. 26. P. 933–960. DOI 10.1007/s11831-018-9266-3.
9. Алгоритм обучения anfis. URL: <https://studfile.net/preview/9501084/page:11/> (дата обращения: 05.04.2024).

Информация об авторах

В. В. Брыкин – аспирант.

М. Я. Брагинский – кандидат технических наук, доцент.

Д. В. Тараканов – кандидат технических наук, доцент.

И. Л. Назарова – аспирант, инженер 1 категории.

References

1. Gurlina E. V. Razrabotka metoda vyivleniia teksturnykh svoistv zadannykh klassov izobrazhenii s ispolzovaniem priznakov Kharalika. In: Prokhorov S. A., editor. *Proceedings of the International Scientific Conference “Advanced Information Technologies and Scientific Computing (PIT 2020)”*, April 21–22, 2020, Samara. Samara: Samara Scientific Center of RAS; 2020. p. 112–116. (In Russ.).
2. Lofstedt T., Brynolfsson P., Asklund T. Gray-level invariant Haralick texture features. *PLoS ONE*. 2019;14(2):e0212110.
3. Brykin V. V., Braginsky M. Ya., Tarakanov D. V. et al. Classification of plants health via texture wavelet analysis and machine learning. *Proceedings in Cybernetics*. 2024;23(1):23–30. DOI 10.35266/1999-7604-2024-1-3. (In Russ.).
4. Vyas A., Paik J. Review of the application of wavelet theory to image processing. *IEIE Transactions on Smart Processing & Computing*. 2016;5(6):403–417. DOI 10.5573/IEIESPC.2016.5.6.403.
5. Balagansky A. Yu., Grebenkov A. A. Wavelet transformation for image processing of a heating control system using machine learning methods. *Informatatsiia i obrazovanie: granitsy kommunikatsii*. 2022;(14):147–150. (In Russ.).
6. Mahajan V., Dhumale N. R. Leaf disease detection using fuzzy logic. *International Journal of Innovative Research in Science, Engineering and Technology*. 2018;7(6):6801–6807. DOI 10.15680/IJIR-SET.2018.0706067.
7. Ashish P., Tanuja P. Survey on detection and classification of plant leaf disease in agriculture environment. *International Advanced Research Journal in Science, Engineering and Technology*. 2017;4(4):137–139. DOI 10.17148/iarjset/nciarcse.2017.40.
8. Thyagarajan K. K., Kiruba Raji I. A review of visual descriptors and classification techniques used in leaf species identification. *Archives of Computational Methods in Engineering*. 2019;26:933–960. DOI 10.1007/s11831-018-9266-3.
9. Algoritm obucheniia anfis. URL: <https://studfile.net/preview/9501084/page:11/> (accessed: 05.04.2024). (In Russ.).

Information about the authors

V. V. Brykin – Postgraduate.

M. Ya. Braginsky – Candidate of Sciences (Engineering), Docent.

D. V. Tarakanov – Candidate of Sciences (Engineering), Docent.

I. L. Nazarova – Postgraduate, 1st Category Engineer.