

# **BREAST CANCER DIAGNOSIS USING FUZZY SYSTEMS**

Full 1403

**WRITE:**  
Pariya Afsharipour  
403125784

**Submitted to:**  
Dr. Hosseini

## فهرست مطالعه

۱. فصل ۱: تحلیل مسئله
  - ۱-۱ شرح پژوهش ○
  - ۱-۲ دیتاست مورد استفاده ○
  - ۱-۳ تحلیل داده‌های ورودی مسئله ○
  - ۱-۴ سایر منابع ○
۲. فصل ۲: انتخاب ویژگی و توابع عضویت
  - ۲-۱ پیش‌پردازش و انتخاب ویژگی با استفاده از PCA ○
  - ۲-۲ انتخاب شکل تابع عضویت ○
  - ۲-۳ پارامترهای توابع عضویت ○
  - ۲-۴ کدهای مرتبط با FCM و PCA ○
۳. فصل ۳: سیستم هوشمند فازی ممدانی
  - ۳-۱ سیستم فازی ممدانی ○
  - ۳-۲ شیوه استفاده از توابع عضویت ○
  - ۳-۳ فازی‌سازی ○
  - ۳-۴ قوانین فازی ممدانی ○
  - ۳-۵ غیرفازی‌سازی ○
  - ۳-۶ ارزیابی سیستم ○
  - ۳-۷ بررسی یک نمونه ○
۴. فصل ۴: سیستم هوشمند فازی سوگنو
  - ۴-۱ معرفی سیستم فازی سوگنو ○
  - ۴-۲ شیوه استفاده از توابع عضویت ○
  - ۴-۳ پایگاه قوانین ○
  - ۴-۴ ارزیابی سیستم ○
۵. فصل ۵: بهبود عملکرد سوگنو با استفاده از تغییرپذیری
  - ۵-۱ افزودن یادگیری به سیستم فازی با الگوریتم ژنتیک ○
  - ۵-۲ اجرای الگوریتم‌های DE برای بهینه‌سازی وزن‌ها ○
۶. فصل ۶: استفاده از روش یادگیری میشیگان برای ایجاد پایگاه قوانین
  - ۶-۱ الگوریتم میشیگان ○
  - ۶-۲ کدنویسی و ارزیابی عملکرد ○
۷. فصل ۷: استفاده از روش یادگیری پیتزبورگ برای ایجاد پایگاه قوانین
  - ۷-۱ الگوریتم پیتزبورگ ○
  - ۷-۲ کدنویسی و ارزیابی عملکرد ○
۸. فصل ۸: سیستم فازی نوع ۲ و مقایسه با نوع ۱ \* \* بخش امتیازی
  - ۸-۱ معرفی سیستم فازی نوع ۲ ○
  - ۸-۲ کدنویسی سیستم فازی نوع ۲ ○
  - ۸-۳ مقایسه فازی نوع ۱ و نوع ۲ ○

فصل اول:

## تحليل مسئله

## ۱-۱ شرح پروژه

هدف اصلی این پروژه طراحی یک سیستم فازی برای ارزیابی و برچسب‌گذاری نوع سرطان سینه است. سیستم طراحی شده قادر خواهد بود نوع توده‌های سرطانی را به دو دسته خوش‌خیم (Benign) و بدخیم (Malignant) طبقه‌بندی کند. این سیستم با استفاده از قوانین فازی و داده‌های معتبر، سعی در ارائه یک سیستم دارد که دقیق‌تر بالایی داشته باشد.

## ۱-۲ دیتاست مورد استفاده

دیتاست مورد استفاده در این پروژه، Breast Cancer Wisconsin (Diagnostic) یکی از مجموعه داده‌های معروف و معتبر در زمینه تشخیص سرطان سینه به شمار می‌رود. این دیتاست شامل اطلاعاتی از توده‌های سرطانی است. ویژگی‌های موجود در این دیتاست به توصیف مشخصات فیزیکی و آماری سلول‌های توده‌ها می‌پردازد.

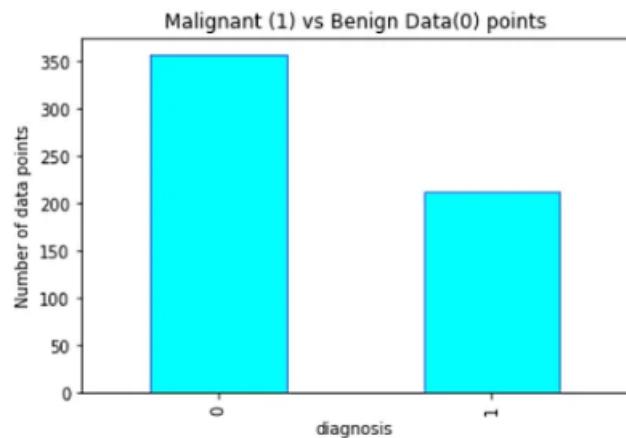
### ۱-۱-۱ ویژگی‌های دیتاست

دیتاست شامل ۵۶۹ نمونه است و شامل ۳۰ ویژگی عددی می‌شود. این ویژگی‌ها برای توصیف ویژگی‌های سلول‌های سرطانی استفاده می‌شوند. در جدول زیر، بخشی از ویژگی‌های موجود در دیتاست به همراه دامنه مقادیر آنها ارائه شده است:

حداکثر مقدار	حداقل مقدار	توضیحات	ویژگی	شماره
28.11	6.981	میانگین شعاع سلول	Radius Mean	1
39.28	9.71	میانگین بافت سلول	Texture Mean	2
188.5	43.79	میانگین محیط سلول	Perimeter Mean	3
2501	143.5	میانگین مساحت سلول	Area Mean	4
0.1634	0.05263	میانگین صافی سلول	Smoothness Mean	5
0.3454	0.01938	میانگین فشردگی سلول	Compactness Mean	6
0.4268	0	میانگین فرورفتگی سلول	Concavity Mean	7

0.2012	0	میانگین نقاط فرورفته	Concave Points Mean	8
0.304	0.106	میانگین تقارن سلول	Symmetry Mean	9

### ۱-۳ تحلیل داده های ورودی مسئله



شکل ۱-۱

در نمودار بالا می توانیم نسبت داده های ۲ کلاس در دیتاست مشاهده کنیم.

۶۷٪ داده ها برای کلاس خوش خیم و ۳۷٪ داده ها برای کلاس بد خیم است.

### ۱-۴ سایر منابع

برای پیاده سازی این پروژه از محیط Google Colab و زبان برنامه نویسی پایتون استفاده شده است.

فصل دوم:

## انتخاب ویژگی و توابع عضویت

## ۲-۱ پیش‌پردازش و انتخاب ویژگی با استفاده از PCA

در پیش‌پردازش داده‌ها و انتخاب ویژگی‌ها از الگوریتم PCA برای کاهش ابعاد و پیچیدگی داده‌ها استفاده شده است. این الگوریتم به منظور کاهش ابعاد داده‌ها و حفظ بیشترین واریانس ممکن، ویژگی‌های را انتخاب کرده است که بیشترین اطلاعات را در خود دارند. ۸ ویژگی، به عنوان ورودی‌های مدل انتخاب شده‌اند.

## ۲-۲ انتخاب شکل تابع عضویت

از بین انواع شکل‌های تابع عضویت مانند مثلثی، ذوالذنقه، گوسی، زنگوله‌ای و... تابع گوسی برای این پروژه انتخاب شده است. تابع گوسی از فرمول زیر تبعیت می‌کند، که در آن  $\mu$  مرکز و  $\sigma$  پهنای تابع را مشخص می‌کند.

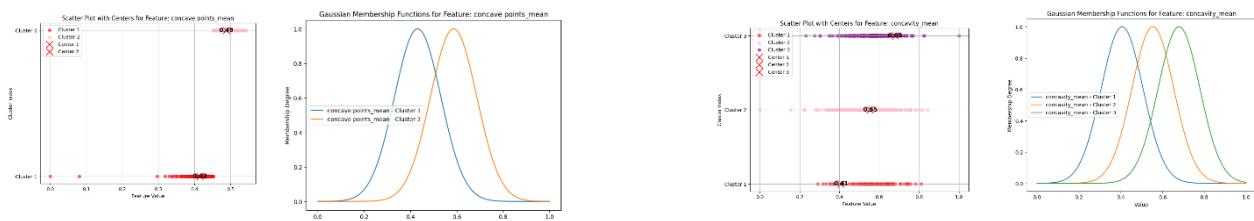
$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}(\frac{x-\mu}{\sigma})^2}$$

فرمول ۱-۱

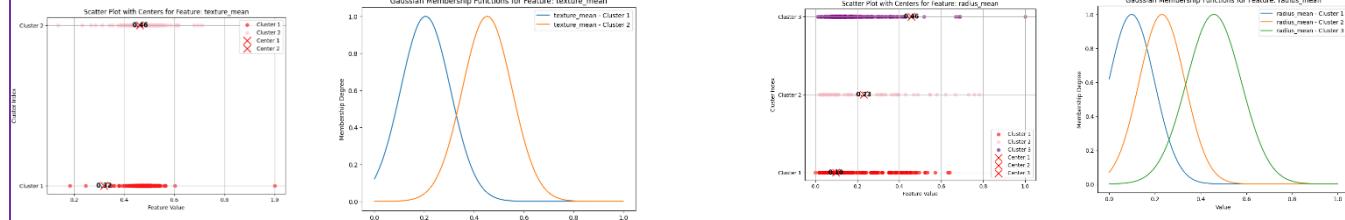
## ۲-۳ پارامترهای توابع عضویت

به منظور تنظیم پارامترهای توابع عضویت در این پروژه، از الگوریتم FCM استفاده شده است. این الگوریتم یکی از روش‌های قدرتمند در خوشه‌بندی داده‌ها است و به هر داده یک درجه عضویت نسبت به هر خوشه اختصاص می‌دهد. در این پروژه، الگوریتم FCM داده‌های هر ویژگی را تحلیل می‌کند و با ایجاد خوشه‌های فازی، مقادیر میانگین و پراکندگی داده‌ها در هر خوشه را مشخص می‌کند. با استفاده از FCM هر ورودی به ۲ تا ۳ خوشه تقسیم شده است.

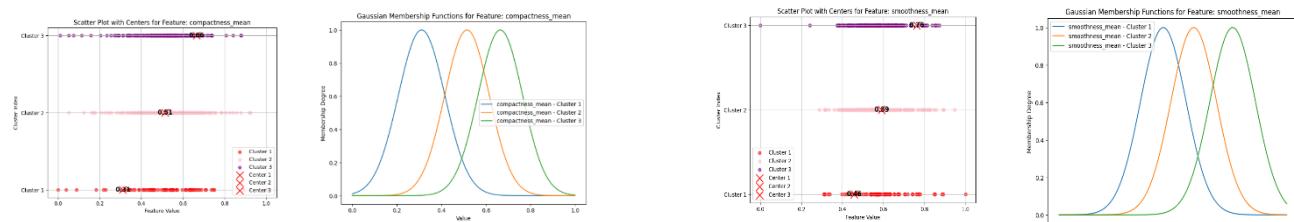
در ادامه پلات های نتیجه این الگوریتم با استفاده از کتابخانه matplotlib رسم شده اند:



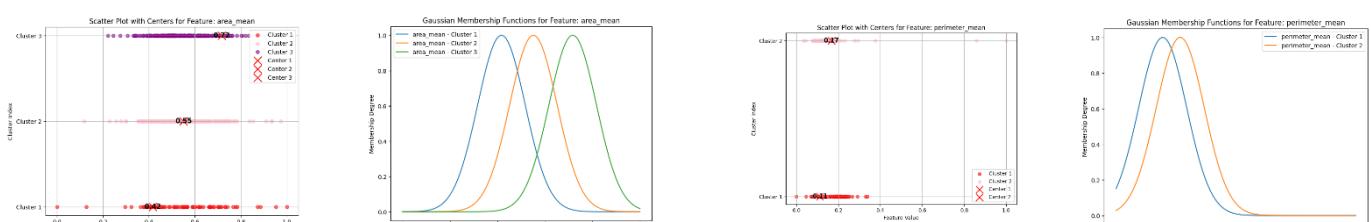
شکل ۱-۲ نمودار گوسی و مرکز خوش برای میانگین فورفتگی و تعداد فورفتگی



شکل ۲-۲ نمودار گوسی و مرکز خوش برای میانگین شعاع و میانگین بافت



شکل ۲-۳ نمودار گوسی و مرکز خوش برای میانگین فشردگی و میانگین نرمی



شکل ۲-۴ نمودار گوسی و خوش برای میانگین مساحت و میانگین محیطی

همچنین جدول زیر بازه هر کدام از عبارت زبانی مربوط به هر ویژگی را نمایش می دهد:

توضیحات	عبارت فازی	مقدار بازه	Cluster	ویژگی
---------	------------	------------	---------	-------

اندازه کوچک توده	کوچک	0.00 – 0.17	1	radius_mean
اندازه متوسط توده	متوسط	0.17 – 0.34	2	
اندازه بزرگ توده	بزرگ	0.35 – 1.00	3	
بافت نرم توده	نرم	0.00 – 0.29	1	texture_mean
بافت سخت توده	سخت	0.42 – 0.47	2	
محیط کوچکتر	کوچک	0.23 – 0.40	1	perimeter_mean
محیط بزرگتر	متوسط	0.18 – 0.22	2	
مساحت کوچک توده	کوچک	0.00 – 0.48	1	area_mean
مساحت متوسط توده	متوسط	0.49 – 0.63	۲	
مساحت بزرگ توده	بزرگ	0.63 – 1.00	۳	
توده نرم	نرم	0.00 – 0.52	1	smoothness_mean
توده متوسط	متوسط	0.53 – 0.68	۲	
توده سخت	سخت	0.68 – 1.00	۳	
تراکم کم توده	کم تراکم	0.00 – 0.42	1	compactness_mean
تراکم متوسط توده	متراتکم	0.53 – 0.68	۲	
تراکم زیاد توده (بدخیم)	پرتراتکم	0.68 – 1.00	۳	
میزان فرورفتگی کم	منظم	0.00 – 0.48	1	concavity_mean
میزان فرورفتگی متوسط	شبه منظم	0.48 – 0.61	۲	
میزان فرورفتگی زیاد	نامنظم	0.62 – 1.00	۳	
تعداد نقاط فرورفتگی کم	کم	0.00 – 0.39	1	concave points_mean
تعداد نقاط فرورفتگی زیاد	زیاد	0.62 – 0.70	2	

## ۲-۴ کد

در ادامه به توضیح کد این بخش می پردازیم:

### ۲-۴-۱ کتابخانه های مورد نیاز

برای استفاده از الگوریتم FCM نیاز به نصب کتابخانه scikit-fuzzy داشتم و همچنین برای دسترسی به دیتاست به شکل زیر عمل کرده ام.

```
!pip install scikit-fuzzy
!pip install kaggle
!mkdir -p ~/.kaggle
!cp kaggle.json ~/.kaggle/
!chmod 600 ~/.kaggle/kaggle.json

!kaggle datasets download -d uciml/breast-cancer-wisconsin-data
!unzip breast-cancer-wisconsin-data.zip

from sklearn.preprocessing import MinMaxScaler
from sklearn.decomposition import PCA
import pandas as pd
import numpy as np
import skfuzzy as fuzz
```

### ۲-۴-۲ استفاده از الگوریتم fcm و pca

پس از انتخاب ویژگی های ورودی و کاهش ابعاد با استفاده از PCA ، داده ها را نرمال سازی می شوند. سپس، الگوریتم FCM روی هر ویژگی اعمال می شود تا داده ها به چند خوشه تقسیم شوند

```
data = pd.read_csv("data.csv")

X = data.iloc[:, 2:-1].values
feature_names = data.columns[2:-1]

pca = PCA(n_components=8)
X_pca = pca.fit_transform(X)

scaler = MinMaxScaler()
X_scaled = scaler.fit_transform(X_pca)

fcm_params = {}

for feature_idx in range(X_scaled.shape[1]):
```

```

x_vals = X_scaled[:, feature_idx].reshape(1, -1)
best_clusters = 3
if feature_names[feature_idx] in ["texture_mean", "perimeter_mean", "concave
points_mean"]:
    best_clusters = 2

cntr, u, _, _, _, _ = fuzz.cluster.cmeans(
    x_vals, c=best_clusters, m=2, error=0.005, maxiter=1000, init=None
)

feature_gaussians = []
for i in range(best_clusters):
    cluster_data = x_vals[0, np.argmax(u, axis=0) == i]

    if len(cluster_data) > 1:
        mean = np.mean(cluster_data)
        sigma = max(np.std(cluster_data), 0.1)
    else:
        mean = np.mean(cluster_data)
        sigma = 0.1

    feature_gaussians.append((mean, sigma))

fcm_params[feature_names[feature_idx]] = feature_gaussians

```

اطلاعات به دست آمده از اجرای الگوریتم FCM داخل فایل جیسون ذخیره شد تا در ادامه برای طراحی سیستم مورد استفاده قرار گیرد.

# فصل سوم

## سیستم هوشمند فازی ممدادانی

## ۳-۱ سیستم فازی ممدانی

سیستم فازی ممدانی بر اساس قوانین "اگر-آنگاه" عمل می‌کند. در این سیستم، مقادیر ورودی به مجموعه‌های فازی تبدیل می‌شوند، سپس با استفاده از قوانین فازی خروجی فازی تولید می‌شود و در نهایت با غیرفازی سازی به یک مقدار دقیق تبدیل می‌گردد.

## ۳-۲ شیوه استفاده از توابع عضویت

برای طراحی این سیستم ممدانی و ۲ فصل بعدی از نتیجه الگوریتم FCM و PCA فصل قبل استفاده شده است. به منظور استفاده از نتایج با کد زیر فایل json در گوگل کولب لود کردم:

```
with open("fcm_results.json", "r") as json_file:  
    fcm_params = json.load(json_file)
```

## ۳-۳ فازی سازی

این مرحله، مقادیر ورودی به کمک توابع عضویت به مجموعه‌های فازی تبدیل می‌شوند. این کار باعث می‌شود داده‌های واقعی به زبان فازی تبدیل شوند.

در `fuzzify_data_point` برای هر ویژگی، یک تابع فازی تعریف شده که بر اساس بازه‌های مشخص، درجه عضویت مقادیر را در دسته‌های مختلف (مثل کوچک، متوسط یا بزرگ) محاسبه می‌کند. در نهایت، تابع `convert_fuzzy_to_categories` برای هر ویژگی، دسته‌ای که بیشترین درجه عضویت را دارد به عنوان دسته نهایی انتخاب می‌کند:

```
def fuzzify_radius_mean(value):  
    if value < 12:  
        return {"small": 1.0, "medium": 0.0, "large": 0.0}  
    elif 12 <= value <= 18:  
        return {"small": (18 - value) / 6, "medium": (value - 12) / 6, "large": 0.0}  
    elif 18 < value <= 25:  
        return {"small": 0.0, "medium": (25 - value) / 7, "large": (value - 18) / 7}  
    else:  
        return {"small": 0.0, "medium": 0.0, "large": 1.0}
```

```

def fuzzify_texture_mean(value):
    if value < 10:
        return {"soft": 1.0, "medium": 0.0, "hard": 0.0}
    elif 10 <= value <= 20:
        return {"soft": (20 - value) / 10, "medium": (value - 10) / 10, "hard": 0.0}
    elif 20 < value <= 30:
        return {"soft": 0.0, "medium": (30 - value) / 10, "hard": (value - 20) / 10}
    else:
        return {"soft": 0.0, "medium": 0.0, "hard": 1.0}

def fuzzify_perimeter_mean(value):
    if value < 50:
        return {"small": 1.0, "medium": 0.0, "large": 0.0}
    elif 50 <= value <= 100:
        return {"small": (100 - value) / 50, "medium": (value - 50) / 50, "large": 0.0}
    elif 100 < value <= 150:
        return {"small": 0.0, "medium": (150 - value) / 50, "large": (value - 100) / 50}
    else:
        return {"small": 0.0, "medium": 0.0, "large": 1.0}

def fuzzify_area_mean(value):
    if value < 400:
        return {"small": 1.0, "medium": 0.0, "large": 0.0}
    elif 400 <= value <= 700:
        return {"small": (700 - value) / 300, "medium": (value - 400) / 300, "large": 0.0}
    elif 700 < value <= 1000:
        return {"small": 0.0, "medium": (1000 - value) / 300, "large": (value - 700) / 300}
    else:
        return {"small": 0.0, "medium": 0.0, "large": 1.0}

def fuzzify_smoothness_mean(value):
    if value < 0.1:
        return {"soft": 1.0, "medium": 0.0, "hard": 0.0}
    elif 0.1 <= value <= 0.2:
        return {"soft": (0.2 - value) / 0.1, "medium": (value - 0.1) / 0.1, "hard": 0.0}
    elif 0.2 < value <= 0.3:
        return {"soft": 0.0, "medium": (0.3 - value) / 0.1, "hard": (value - 0.2) / 0.1}
    else:
        return {"soft": 0.0, "medium": 0.0, "hard": 1.0}

```

```

def fuzzify_compactness_mean(value):
    if value < 0.05:
        return {"low": 1.0, "medium": 0.0, "high": 0.0}
    elif 0.05 <= value <= 0.15:
        return {"low": (0.15 - value) / 0.1, "medium": (value - 0.05) / 0.1,
"high": 0.0}
    elif 0.15 < value <= 0.3:
        return {"low": 0.0, "medium": (0.3 - value) / 0.15, "high": (value - 0.15)
/ 0.15}
    else:
        return {"low": 0.0, "medium": 0.0, "high": 1.0}

def fuzzify_concavity_mean(value):
    if value < 0.1:
        return {"low": 1.0, "medium": 0.0, "high": 0.0}
    elif 0.1 <= value <= 0.2:
        return {"low": (0.2 - value) / 0.1, "medium": (value - 0.1) / 0.1, "high": 0.0}
    elif 0.2 < value <= 0.4:
        return {"low": 0.0, "medium": (0.4 - value) / 0.2, "high": (value - 0.2) /
0.2}
    else:
        return {"low": 0.0, "medium": 0.0, "high": 1.0}

def fuzzify_concave_points_mean(value):
    if value < 0.05:
        return {"low": 1.0, "medium": 0.0, "high": 0.0}
    elif 0.05 <= value <= 0.15:
        return {"low": (0.15 - value) / 0.1, "medium": (value - 0.05) / 0.1,
"high": 0.0}
    elif 0.15 < value <= 0.25:
        return {"low": 0.0, "medium": (0.25 - value) / 0.1, "high": (value - 0.15)
/ 0.1}
    else:
        return {"low": 0.0, "medium": 0.0, "high": 1.0}

def fuzzify_data_point(crisp_data_point):
    return {
        "radius_mean": fuzzify_radius_mean(crisp_data_point["radius_mean"]),
        "texture_mean": fuzzify_texture_mean(crisp_data_point["texture_mean"]),
        "perimeter_mean": fuzzify_perimeter_mean(crisp_data_point["perimeter_mean"]),
        "area_mean": fuzzify_area_mean(crisp_data_point["area_mean"]),
        "smoothness_mean": fuzzify_smoothness_mean(crisp_data_point["smoothness_mean"]),
        "compactness_mean": fuzzify_compactness_mean(crisp_data_point["compactness_mean"]),
    }

```

۴-۳ قوانین فازی ممدادانی

۴ نمونه از این قوانین در کد زیر قرار دادم:  
۴۰ قانون با استفاده از عبارت های فازی متناظر با متغیر های فازی این سیستم نوشته شده است.  
مجموعه‌ای از قوانین "اگر-آنگاه" هستند که روابط بین ورودی‌ها و خروجی‌ها را تعریف می‌کنند

```
def apply_fuzzy_rules(data_point):
    results = []
    if (data_point['radius_mean'] == "small" and
        data_point['texture_mean'] == "medium" and
        data_point['smoothness_mean'] == "soft"):
        results.append("Benign")

    if (data_point['radius_mean'] == "medium" and
        data_point['texture_mean'] == "soft" and
        data_point['compactness_mean'] == "low"):
        results.append("Relatively Benign")

    if (data_point['radius_mean'] == "large" and
        data_point['texture_mean'] == "soft" and
        data_point['compactness_mean'] == "high"):
        results.append("Malignant")

    if (data_point['area_mean'] == "large" and
        data_point['smoothness_mean'] == "hard" and
        data_point['perimeter_mean'] == "small"):
        results.append("Malignant")
```

## ۳-۵ غیرفازی سازی

در این مرحله، خروجی‌های فازی به یک مقدار دقیق تبدیل می‌شوند. این مقدار نشان‌دهنده نتیجه نهایی سیستم فازی است.

در این مسئله از میانگین وزنی به منظور غیرفازی استفاده شده است:

```
def defuzzify(results, fuzzy_map):
    result_counts = Counter(results)

    weighted_sum = sum(fuzzy_map[result] * count for result, count in
result_counts.items())

    total_weight = sum(result_counts.values())

    return weighted_sum / total_weight if total_weight > 0 else 0

fuzzy_map = {
    'Malignant': 90,
    'Relatively Malignant' : 70,
    'Relatively Benign': 30,
    'Benign': 20
}
```

## ۳-۶ ارزیابی سیستم

عملکرد سیستم ممدادی با داده‌های دیتابیس مورد ارزیابی قرار گرفته‌اند:

```
from sklearn.metrics import mean_squared_error, roc_auc_score, roc_curve

data = pd.read_csv("data.csv")
data.rename(columns={'concave points_mean': 'concave_points_mean'}, inplace=True)

features = ['radius_mean', 'texture_mean', 'perimeter_mean', 'area_mean',
'sMOOTHNESS_mean',
        'compactness_mean', 'concavity_mean', 'concave_points_mean']
X = data[features]
y = data['diagnosis'].map({'B': 0, 'M': 1

def apply_fuzzy_system(row):
    row = dict(row)
```

```

fuzzy_data_point = fuzzify_data_point(row)
data_point = convert_fuzzy_to_categories(fuzzy_data_point)
classification_results = apply_fuzzy_rules(data_point)
fuzzy_output = defuzzify(classification_results, fuzzy_map)
return 0 if fuzzy_output < 50 else 1

predictions = X.apply(apply_fuzzy_system, axis=1)

mse = mean_squared_error(y, predictions)
print(f"Mean Squared Error (MSE): {mse:.4f}")
rmse = np.sqrt(mse)
print(f"Root Mean Squared Error (RMSE): {rmse:.4f}")

auc = roc_auc_score(y, predictions)
print(f"Area Under the Curve (AUC): {auc:.4f}")

```

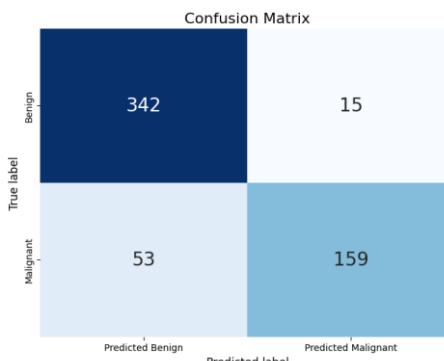
نتایج به دست آمده برای سیستم ممدادی تشخیص سرطان سینه:

Mean Squared Error (MSE): 0.1195

Root Mean Squared Error (RMSE): 0.3457

Area Under the Curve (AUC): 0.8540

همچنین ماتریس سردرگمی این سیستم به شکل زیر می باشد:



شکل ۳-۱ ماتریس سردرگمی

### ۳-۸ بررسی یک نمونه

در کد زیر به بررسی یک نمونه با سیستم طراحی شده پرداخته ام:

```

crisp_data_point = {
    "radius_mean": 17.99,
    "texture_mean": 15.23,
    "perimeter_mean": 80.23,
}

```

```
"area_mean": 500.0,  
"smoothness_mean": 0.18,  
"compactness_mean": 0.12,  
"concavity_mean": 0.2,  
"concave_points_mean": 0.2,  
}  
  
fuzzy_data_point = fuzzify_data_point(crisp_data_point)  
data_point = convert_fuzzy_to_categories(fuzzy_data_point)  
classification_results = apply_fuzzy_rules(data_point)  
final_output = defuzzify(classification_results, fuzzy_map)
```

مقدار نهایی برابر با ۷۲ بود که کلاس را به درستی پیش بینی کرد.

## فصل ۴

### سیستم هوشمند فازی سوگنو

## ۱-۴ سیستم فازی سوگنو

سیستم فازی سوگنو یک نوع سیستم فازی است که در آن قوانین فازی به صورت توابع خطی یا غیرخطی برای محاسبه خروجی استفاده می‌شود. برخلاف سیستم فازی ممداňی که در آن خروجی‌ها به صورت مجموعه‌های فازی تولید می‌شوند و سپس با روش‌هایی مانند *centroid of area* به یک مقدار دقیق تبدیل می‌شوند، در سیستم فازی سوگنو، خروجی‌ها مستقیماً از ترکیب توابع ریاضی به دست می‌آیند.

## ۲-۴ شیوه استفاده از توابع عضویت و فازی سازی

این بخش مانند بخش ۲-۳ و ۳-۳ در فصل ۳ می‌باشد. به همین دلیل آورده نشده است.

## ۳-۴ پایگاه قوانین

قوانین فازی سوگنو، نوع دیگری از قوانین فازی هستند که در آنها قسمت "آنگاه" قانون به جای یک عبارت فازی، یک تابع ریاضی (معمولًاً خطی) است. به عبارتی خروجی هر قانون یک مقدار عددی دقیق است.

در کد زیر کل قوانین سوگنو سیستم آورده شده است:

```
def fuzzy_sogeno_rules(crisp_data_point, fuzzy_data_point):
    rules = []
    weights = []

    if fuzzy_data_point['radius_mean']['small'] > 0:
        weights.append(fuzzy_data_point['radius_mean']['small'])
        rules.append(2)

    if fuzzy_data_point['radius_mean']['medium'] > 0:
        weights.append(fuzzy_data_point['radius_mean']['medium'])
        rules.append(4 * crisp_data_point['radius_mean'])

    if fuzzy_data_point['radius_mean']['large'] > 0:
        weights.append(fuzzy_data_point['radius_mean']['large'])
        rules.append(8 * crisp_data_point['radius_mean'])
```

```

if fuzzy_data_point['texture_mean']['soft'] > 0:
    weights.append(fuzzy_data_point['texture_mean']['soft'])
    rules.append(3)

if fuzzy_data_point['texture_mean']['medium'] > 0:
    weights.append(fuzzy_data_point['texture_mean']['medium'])
    rules.append(5 * crisp_data_point['texture_mean'])

if fuzzy_data_point['texture_mean']['hard'] > 0:
    weights.append(fuzzy_data_point['texture_mean']['hard'])
    rules.append(7 * crisp_data_point['texture_mean'])

if fuzzy_data_point['perimeter_mean']['small'] > 0:
    weights.append(fuzzy_data_point['perimeter_mean']['small'])
    rules.append(2)

if fuzzy_data_point['perimeter_mean']['medium'] > 0:
    weights.append(fuzzy_data_point['perimeter_mean']['medium'])
    rules.append(6 * crisp_data_point['perimeter_mean'])

if fuzzy_data_point['perimeter_mean']['large'] > 0:
    weights.append(fuzzy_data_point['perimeter_mean']['large'])
    rules.append(10 * crisp_data_point['perimeter_mean'])

if fuzzy_data_point['area_mean']['medium'] > 0:
    weights.append(fuzzy_data_point['area_mean']['medium'])
    rules.append(4 * crisp_data_point['area_mean'])

if fuzzy_data_point['area_mean']['large'] > 0:
    weights.append(fuzzy_data_point['area_mean']['large'])
    rules.append(9 * crisp_data_point['area_mean'])

if fuzzy_data_point['smoothness_mean']['soft'] > 0:
    weights.append(fuzzy_data_point['smoothness_mean']['soft'])
    rules.append(1.5)

if fuzzy_data_point['smoothness_mean']['medium'] > 0:
    weights.append(fuzzy_data_point['smoothness_mean']['medium'])
    rules.append(3 * crisp_data_point['smoothness_mean'])

if fuzzy_data_point['smoothness_mean']['hard'] > 0:
    weights.append(fuzzy_data_point['smoothness_mean']['hard'])
    rules.append(5 * crisp_data_point['smoothness_mean'])

if fuzzy_data_point['compactness_mean']['low'] > 0:
    weights.append(fuzzy_data_point['compactness_mean']['low'])
    rules.append(1)

```

```

if fuzzy_data_point['compactness_mean']['medium'] > 0:
    weights.append(fuzzy_data_point['compactness_mean']['medium'])
    rules.append(3 * crisp_data_point['compactness_mean'])

if fuzzy_data_point['compactness_mean']['high'] > 0:
    weights.append(fuzzy_data_point['compactness_mean']['high'])
    rules.append(6 * crisp_data_point['compactness_mean'])

if fuzzy_data_point['concavity_mean']['low'] > 0:
    weights.append(fuzzy_data_point['concavity_mean']['low'])
    rules.append(1.5)

if fuzzy_data_point['concavity_mean']['medium'] > 0:
    weights.append(fuzzy_data_point['concavity_mean']['medium'])
    rules.append(4 * crisp_data_point['concavity_mean'])

if fuzzy_data_point['concavity_mean']['high'] > 0:
    weights.append(fuzzy_data_point['concavity_mean']['high'])
    rules.append(8 * crisp_data_point['concavity_mean'])

if fuzzy_data_point['concave_points_mean']['low'] > 0:
    weights.append(fuzzy_data_point['concave_points_mean']['low'])
    rules.append(2)

if fuzzy_data_point['concave_points_mean']['high'] > 0:
    weights.append(fuzzy_data_point['concave_points_mean']['high'])
    rules.append(6 * crisp_data_point['concave_points_mean'])

if sum(weights) == 0:
    return 0.5
resistance = sum(w * r for w, r in zip(weights, rules)) / sum(weights)
return resistance

```

نکته: در سوگنو بخشی به عنوان defuzzification نداریم.

## ۴-۵ ارزیابی سیستم

```

data = pd.read_csv("data.csv")
data.rename(columns={'concave points_mean': 'concave_points_mean'}, inplace=True)

features = [
    'radius_mean', 'texture_mean', 'perimeter_mean', 'area_mean',
    'smoothness_mean', 'compactness_mean', 'concavity_mean', 'concave_points_mean'
]
X = data[features]

```

```

y = data['diagnosis'].map({'B': 0, 'M': 1})

def apply_fuzzy_system(row):
    crisp_data_point = row
    fuzzy_data_point = fuzzify_data_point(crisp_data_point)
    classification_result = fuzzy_sogeno_rules(crisp_data_point, fuzzy_data_point)
    return 0 if classification_result < 50 else 1

X = data[features]
y = data['diagnosis'].map({'B': 0, 'M': 1})

predictions = X.apply(apply_fuzzy_system, axis=1)

accuracy = accuracy_score(y, predictions)
print(f"Accuracy of the Fuzzy System: {accuracy * 100:.2f}%")

error = (predictions != y).mean()
print(f"Mean Absolute Error (MAE): {error:.4f}")

accuracy = accuracy_score(y, predictions)
print(f"Accuracy of the Fuzzy System: {accuracy * 100:.2f}%")

mse = mean_squared_error(y, predictions)
print(f"Mean Squared Error (MSE): {mse:.4f}")

rmse = np.sqrt(mse)
print(f"Root Mean Squared Error (RMSE): {rmse:.4f}")

auc = roc_auc_score(y, predictions)
print(f"Area Under the Curve (AUC): {auc:.4f}")

```

نتایج به دست آمده به شکل زیر است:

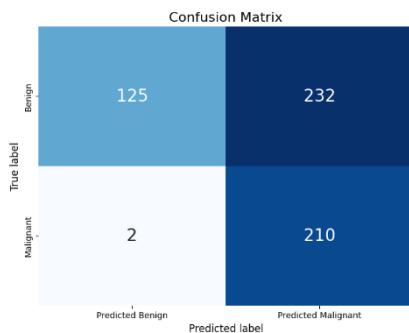
Accuracy of the Fuzzy System: 58.88%

Mean Squared Error (MSE): 0.4112

Root Mean Squared Error (RMSE): 0.6413

Area Under the Curve (AUC): 0.6704

همچنین نتیجه ماتریس سردرگمی به شکل این است:



شکل ۴-۱ ماتریس سردرگمی

همانطور که مشخص است دقت سیستم ممداً بیتر بود.

## فصل ۵

### بهبود عملکرد سوگنو با استفاده تغییرپذیری

## ۱-۵ افزودن یادگیری به سیستم فازی با استفاده از الگوریتم ژنتیک

سیستم‌های فازی به طور ذاتی فاز یادگیری ندارند، زیرا قوانین و پارامترهای آن‌ها معمولاً به صورت دستی و بر اساس دانش فرد خبره تعیین می‌شوند. با این حال، می‌توان از الگوریتم‌های بهینه‌سازی مانند الگوریتم ژنتیک برای تنظیم دقیق (tuning) ضرایب و وزن‌های قوانین استفاده کرد.

## ۲-۵ کد

با استفاده از قابلیت tuning process برای هر قانون وزنی در نظر گرفته شده تا میزان مشارکت هر قانون در میانگین وزنی متفاوت باشد. با اینکار قوانین قوی تر و کارآمدتر دارای وزن‌های بیشتری هستند و آن‌هایی که ضعیف‌تر هستند با داده‌های کمتری سازگاری دارند حذف می‌شوند.

## ۱-۲-۵ تغییر ساختار قوانین سوگنو

به منظور اعمال وزن ساختار ۲۳ قانون نوشته شده سوگنو به شکل زیر تغییر دادم. ۳ مورد برای مثال در زیر آورده شده است:

```
def fuzzy_sogeno_rules_with_weights(crisp_data_point, fuzzy_data_point, weights):
    rules = []
    rule_weights = []
    idx = 0

    if fuzzy_data_point['radius_mean']['small'] > 0:
        rule_weights.append(weights[idx])
        rules.append(2 * weights[idx])
        idx += 1
    if fuzzy_data_point['radius_mean']['medium'] > 0:
        rule_weights.append(weights[idx])
        rules.append(4 * crisp_data_point['radius_mean'] * weights[idx])
        idx += 1
    if fuzzy_data_point['radius_mean']['large'] > 0:
        rule_weights.append(weights[idx])
        rules.append(8 * crisp_data_point['radius_mean'] * weights[idx])
        idx += 1
```

## ۵-۲-۲ تعریف تابع fitness مورد نیاز در الگوریتم :de

تابع fitness در الگوریتم تکامل تفاضلی برای ارزیابی ارزش کروموزوم‌ها طراحی شده است. این تابع دقت سیستم فازی سوگنو را با استفاده از وزن‌های پیشنهادی هر کروموزوم می‌سنجد. ابتدا داده‌های ورودی فازی‌سازی می‌شوند و خروجی سیستم با وزن‌های کروموزوم محاسبه می‌شود. سپس با مقایسه خروجی با برچسب‌های واقعی، دقت محاسبه می‌شود.

```
def fitness(chromosome, data, labels):
    def apply_fuzzy_system_with_weights(row, weights):
        crisp_data_point = row
        fuzzy_data_point = fuzzify_data_point(crisp_data_point)
        return fuzzy_sogeno_rules_with_weights(crisp_data_point, fuzzy_data_point,
weights)

    predictions = data.apply(lambda row: apply_fuzzy_system_with_weights(row,
chromosome), axis=1)
    predictions_binary = predictions.apply(lambda x: 1 if x >= 50 else 0)
    accuracy = accuracy_score(labels, predictions_binary)
    return accuracy + np.random.uniform(0, 0.01)
```

## ۵-۲-۳ پیاده سازی الگوریتم :de

تابع differential\_evolution برای بهینه‌سازی وزن‌های سیستم فازی با استفاده از الگوریتم تکامل تفاضلی طراحی شده است. ابتدا جمعیتی از کروموزوم‌ها (وزن‌ها) به صورت تصادفی مقداردهی می‌شوند. در هر نسل، سه کروموزوم تصادفی برای تولید وکتور جهش انتخاب می‌شوند. الگوریتم تا زمانی که بهبود قابل توجهی در Fitness حاصل شود یا تعداد نسل‌ها به حداقل برسد، اجرا می‌شود و در نهایت بهترین کروموزوم و Fitness برگردانده می‌شود.

```
def differential_evolution(data, labels, num_generations=50, population_size=200,
F=0.9, CR=0.95):
    num_weights = 23
    population = np.random.uniform(0, 1, (population_size, num_weights))
    print(f"Initial Population:\n{population}")
    best_fitness = 0
    best_chromosome = None

    for generation in range(num_generations):
        print(f"Generation {generation + 1}: Start")
        fitness_scores = np.array([fitness(chromosome, data, labels) for chromosome
in population])
```

```

print(f"Fitness Scores: {fitness_scores}")

if np.std(fitness_scores) < 0.001:
    print("Early stopping: No significant improvement.")
    break

new_population = []
for i in range(population_size):
    indices = list(range(population_size))
    indices.remove(i)
    a, b, c = population[np.random.choice(indices, 3, replace=False)]
    mutant = a + F * (b - c)
    mutant = np.clip(mutant, 0, 1)

    trial = np.copy(population[i])
    for j in range(num_weights):
        if np.random.rand() < CR:
            trial[j] = mutant[j]

    trial_fitness = fitness(trial, data, labels)
    if trial_fitness > fitness_scores[i]:
        new_population.append(trial)
        if trial_fitness > best_fitness:
            best_fitness = trial_fitness
            best_chromosome = trial
    else:
        new_population.append(population[i])

population = np.array(new_population)

if generation % 5 == 0:
    new_individuals = np.random.uniform(0, 1, (10, num_weights))
    population = np.vstack([population, new_individuals])
    population = population[:population_size]

print(f"New Best Fitness: {best_fitness:.4f}")

if best_chromosome is None:
    best_chromosome = population[0]
    best_fitness = fitness_scores[0]

print(f"Best Fitness: {best_fitness}")
return best_chromosome, best_fitness

```

### ۴-۳-۵ اجرای الگوریتم DE

این بخش از کد وظیفه اجرای الگوریتم تکامل تفاضلی برای یافتن بهترین وزن‌های سیستم فازی را دارد.

```
best_weights, best_accuracy = differential_evolution(X, y, num_generations=100,
population_size=20)
print(f"Best Weights: {best_weights}")

predictions = X.apply(
    lambda row: 1 if fuzzy_sogeno_rules_with_weights(row, fuzzify_data_point(row),
best_weights) >= 0.5 else 0,
    axis=1
)
```

اندازه جمعیت ۲۰ در نظر گرفته شد و به تعداد ۱۰۰ نسل عملیات تکاملی تکرار شد.

نتیجه به دست آمده برای آخرین نسل به این شکل است:

```
Best Weights: [1. 0.34126449 0.31133564 0.44101582 0.54606682 0.66252893
0.17500638 0. 0.36561042 1. 1. 0. 0. 0. 0.08249459 0. 1. 0.86665403
0.1819447 0. 0. 0.30803898 0.94292311]
```

### ۴-۳-۶ ارزیابی عملکرد

```
overall_accuracy = accuracy_score(y, predictions)
print(f"Overall Accuracy: {overall_accuracy:.4f}")

mse = mean_squared_error(y, predictions)
print(f"Mean Squared Error (MSE): {mse:.4f}")

rmse = np.sqrt(mse)
print(f"Root Mean Squared Error (RMSE): {rmse:.4f}")

auc = roc_auc_score(y, predictions)
print(f"Area Under the Curve (AUC): {auc:.4f}")
```

نتایج به دست آمده به شکل زیر است:

Overall Accuracy: 0.3726

Mean Squared Error (MSE): 0.6274

Root Mean Squared Error (RMSE): 0.7921

Area Under the Curve (AUC): 0.5000

## فصل ۵

استفاده از روش یادگیری میشیگان

برای ایجاد پایگاه قوانین

## ۱-۶ الگوریتم میشیگان

الگوریتم میشیگان یکی از روش‌های الگوریتم ژنتیک در یادگیری فازی است که در آن هر کروموزوم یک قانون فازی مجزا را نشان می‌دهد. برخلاف الگوریتم پیتزبورگ، که مجموعه‌ای از قوانین را به طور همزمان ارزیابی می‌کند، در میشیگان هر قانون به صورت جداگانه ارزیابی و بهینه‌سازی می‌شود.

## ۲-۶ توضیحات کد

این کد برای ایجاد یک سیستم یادگیری فازی با استفاده از الگوریتم ژنتیک به روش میشیگان طراحی شده است. ابتدا ویژگی‌های عددی از یک دیتاست فازی‌سازی می‌شوند. بعد، الگوریتم ژنتیک برای تولید قوانینی که می‌توانند داده‌ها را به دسته‌های **malignant** و **benign** طبقه‌بندی کنند، اجرا می‌شود. الگوریتم قوانین اولیه را تولید می‌کند، آن‌ها را بهبود می‌دهد، و بهترین نسل را برای طبقه‌بندی داده‌ها انتخاب می‌کند.

نکته: اطلاعات بخش **fuzzy\_info** از فایل **json** به دست آمده در فصل ۲ است.

## ۱-۶ کد توابع

```
import numpy as np
import pandas as pd
from sklearn.metrics import mean_squared_error, roc_auc_score, roc_curve

def fuzzify_dataset(data):
    return data.apply(lambda row: fuzzify_data_point(row), axis=1)

def convert_fuzzy_to_categories(fuzzy_data):
    result = {}
    for feature, memberships in fuzzy_data.items():
        max_category = max(memberships, key=memberships.get)
        result[feature] = max_category
    return result

def initialize_population(pop_size, fuzzy_info):
    population = []
    for _ in range(pop_size):
```

```

        rule_features = np.random.choice(list(fuzzy_info.keys()), size=4,
replace=False)
        rule_conditions = [
            {
                "feature": feature,
                "fuzzy": np.random.choice([f["fuzzy"] for f in
fuzzy_info[feature]]),
            }
            for feature in rule_features
        ]
        output_fuzzy = np.random.choice(["benign", "malignant"])
        population.append({"conditions": rule_conditions, "output": output_fuzzy})
    return population

def convert_to_readable_rules(rule):
    readable_conditions = " AND ".join([
        f"{condition['feature']} IS {condition['fuzzy']}"
        for condition in rule["conditions"]
    ])
    return f"IF {readable_conditions}, THEN OUTPUT IS {rule['output']}"

def evaluate_rule(rule, data):
    predictions = []
    for _, crisp_data_point in data.iterrows():
        fuzzy_data_point = fuzzify_data_point(crisp_data_point)
        match = True
        for condition in rule["conditions"]:
            feature = condition["feature"]
            fuzzy_label = condition["fuzzy"]
            if fuzzy_data_point[feature][fuzzy_label] == 0:
                match = False
                break
        predictions.append(rule["output"] if match else None)
    return predictions

def evaluate_population(population, data):
    final_predictions = []
    for _, crisp_data_point in data.iterrows():
        for rule in population:
            fuzzy_data_point = fuzzify_data_point(crisp_data_point)
            match = True
            for condition in rule["conditions"]:
                feature = condition["feature"]
                fuzzy_label = condition["fuzzy"]
                if fuzzy_data_point[feature][fuzzy_label] == 0:
                    match = False
                    break
            if match:

```

```

        final_predictions.append(1 if rule["output"] == "malignant" else 0)
        break
    else:
        final_predictions.append(0)
return final_predictions

def crossover(parent1, parent2):
    point = np.random.randint(1, len(parent1["conditions"]))
    child1_conditions = parent1["conditions"][:point] +
parent2["conditions"][point:]
    child2_conditions = parent2["conditions"][:point] +
parent1["conditions"][point:]
    child1 = {"conditions": child1_conditions, "output": parent1["output"]}
    child2 = {"conditions": child2_conditions, "output": parent2["output"]}
    return child1, child2

def mutate(rule, fuzzy_info, mutation_rate):
    if np.random.rand() < mutation_rate:
        idx = np.random.randint(len(rule["conditions"]))
        feature = rule["conditions"][idx]["feature"]
        new_fuzzy = np.random.choice([f["fuzzy"] for f in fuzzy_info[feature]])
        rule["conditions"][idx]["fuzzy"] = new_fuzzy
    if np.random.rand() < mutation_rate:
        rule["output"] = "benign" if rule["output"] == "malignant" else "malignant"
    return rule

def genetic_algorithm(data, labels, pop_size=20, num_generations=100,
mutation_rate=0.1):
    fuzzy_info = {
        "radius_mean": [{"fuzzy": "small"}, {"fuzzy": "medium"}, {"fuzzy": "large"}],
        "texture_mean": [{"fuzzy": "soft"}, {"fuzzy": "medium"}, {"fuzzy": "hard"}],
        "perimeter_mean": [{"fuzzy": "small"}, {"fuzzy": "medium"}, {"fuzzy": "large"}],
        "area_mean": [{"fuzzy": "small"}, {"fuzzy": "medium"}, {"fuzzy": "large"}],
        "smoothness_mean": [{"fuzzy": "soft"}, {"fuzzy": "medium"}, {"fuzzy": "hard"}],
        "compactness_mean": [{"fuzzy": "low"}, {"fuzzy": "medium"}, {"fuzzy": "high"}],
        "concavity_mean": [{"fuzzy": "low"}, {"fuzzy": "medium"}, {"fuzzy": "high"}],
        "concave_points_mean": [{"fuzzy": "low"}, {"fuzzy": "medium"}, {"fuzzy": "high"}],
    }
    population = initialize_population(pop_size, fuzzy_info)

    for generation in range(num_generations):

```

```

        print(f"\nGeneration {generation + 1}")
        for i, rule in enumerate(population):
            readable_rule = convert_to_readable_rules(rule)
            print(f"Rule {i + 1}: {readable_rule}")

    fitness_scores = evaluate_population(population, data)

    print(f"Best Fitness in Generation {generation + 1}:
{max(fitness_scores)}")

    new_population = []
    for i in range(0, pop_size, 2):
        parent1, parent2 = population[i], population[i + 1]
        child1, child2 = crossover(parent1, parent2)
        new_population.extend([mutate(child1, fuzzy_info, mutation_rate),
mutate(child2, fuzzy_info, mutation_rate)])
    population = new_population

    return population

raw_data = pd.read_csv("data.csv")
labels = raw_data['diagnosis'].map({'B': 0, 'M': 1})
raw_data.rename(columns={'concave points_mean': 'concave_points_mean'},
inplace=True)

features = [
    'radius_mean', 'texture_mean', 'perimeter_mean', 'area_mean',
    'smoothness_mean', 'compactness_mean', 'concavity_mean', 'concave_points_mean'
]

final_population = genetic_algorithm(raw_data[features], labels)

print("\nFinal Population:")
for i, rule in enumerate(final_population):
    readable_rule = convert_to_readable_rules(rule)
    print(f"Rule {i + 1}: {readable_rule}")

```

بر اساس ۱۰۰ نسل این الگوریتم بهترین قوانین به دست آمده شامل این ۲۰ قوانین هستند:

Final Population:

Rule 1: IF area\_mean IS small AND radius\_mean IS medium AND compactness\_mean IS medium AND concavity\_mean IS low, THEN OUTPUT IS benign

Rule 2: IF radius\_mean IS small AND area\_mean IS medium AND texture\_mean IS medium AND perimeter\_mean IS large, THEN OUTPUT IS malignant

Rule 3: IF texture\_mean IS soft AND area\_mean IS large AND perimeter\_mean IS medium AND smoothness\_mean IS hard, THEN OUTPUT IS benign

Rule 4: IF concave\_points\_mean IS high AND concavity\_mean IS medium AND radius\_mean IS large AND compactness\_mean IS low, THEN OUTPUT IS malignant

Rule 5: IF perimeter\_mean IS medium AND concavity\_mean IS low AND perimeter\_mean IS large AND texture\_mean IS medium, THEN OUTPUT IS malignant

Rule 6: IF texture\_mean IS soft AND compactness\_mean IS medium AND radius\_mean IS small AND concavity\_mean IS high, THEN OUTPUT IS benign

Rule 7: IF concave\_points\_mean IS low AND texture\_mean IS medium AND concavity\_mean IS low AND compactness\_mean IS low, THEN OUTPUT IS benign

Rule 8: IF area\_mean IS small AND perimeter\_mean IS large AND area\_mean IS medium AND radius\_mean IS medium, THEN OUTPUT IS benign

Rule 9: IF compactness\_mean IS low AND concavity\_mean IS low AND concave\_points\_mean IS high AND radius\_mean IS medium, THEN OUTPUT IS malignant

Rule 10: IF radius\_mean IS large AND compactness\_mean IS high AND area\_mean IS medium AND texture\_mean IS medium, THEN OUTPUT IS benign

Rule 11: IF smoothness\_mean IS medium AND concavity\_mean IS low AND radius\_mean IS medium AND radius\_mean IS large, THEN OUTPUT IS malignant

Rule 12: IF smoothness\_mean IS hard AND texture\_mean IS soft AND texture\_mean IS soft AND concave\_points\_mean IS low, THEN OUTPUT IS benign

Rule 13: IF radius\_mean IS small AND concave\_points\_mean IS low AND area\_mean IS large AND compactness\_mean IS low, THEN OUTPUT IS benign

Rule 14: IF smoothness\_mean IS hard AND perimeter\_mean IS large AND compactness\_mean IS low AND concave\_points\_mean IS high, THEN OUTPUT IS malignant

Rule 15: IF compactness\_mean IS medium AND perimeter\_mean IS small AND smoothness\_mean IS medium AND texture\_mean IS hard, THEN OUTPUT IS malignant

Rule 16: IF smoothness\_mean IS hard AND area\_mean IS large AND concave\_points\_mean IS medium AND area\_mean IS small, THEN OUTPUT IS benign

Rule 17: IF concave\_points\_mean IS medium AND concavity\_mean IS low AND compactness\_mean IS high AND smoothness\_mean IS soft, THEN OUTPUT IS benign

Rule 18: IF compactness\_mean IS high AND area\_mean IS small AND radius\_mean IS small AND concavity\_mean IS low, THEN OUTPUT IS benign

Rule 19: IF concavity\_mean IS medium AND perimeter\_mean IS large AND concave\_points\_mean IS low AND perimeter\_mean IS medium, THEN OUTPUT IS malignant

Rule 20: IF concavity\_mean IS high AND area\_mean IS small AND area\_mean IS large AND compactness\_mean IS low, THEN OUTPUT IS malignant

## ۲-۲-۶ ارزیابی عملکرد

```
accuracy = accuracy_score(labels, final_predictions)
print(f"Accuracy: {accuracy:.4f}")

final_predictions = evaluate_population(final_population, raw_data[features])

mse = mean_squared_error(labels, final_predictions)
print(f"Mean Squared Error (MSE): {mse:.4f}")

rmse = np.sqrt(mse)
print(f"Root Mean Squared Error (RMSE): {rmse:.4f}")

auc = roc_auc_score(labels, final_predictions)
print(f"Area Under the Curve (AUC): {auc:.4f})")
```

نتایج به دست آمده به شکل زیر است:

Accuracy: 0.6292

Mean Squared Error (MSE): 0.1459

Root Mean Squared Error (RMSE): 0.3819

Area Under the Curve (AUC): 0.8129

## فصل ۷

استفاده از روش یادگیری پیتزبورگ

برای ایجاد پایگاه قوانین

## ۱-۷ الگوریتم پیتزبورگ

الگوریتم تکاملی پیتزبورگ یکی از رویکردهای تکاملی برای یادگیری قوانین فازی است که در آن هر کروموزوم یک مجموعه از قوانین فازی را نمایش می‌دهد. برخلاف الگوریتم میشیگان، که در آن هر کروموزوم نماینده یک قانون است، در پیتزبورگ، قوانین به صورت یکجا به شکل rule set تکامل پیدا می‌کند.

## ۲-۷ توضیحات کد

این کد برای ایجاد یک سیستم یادگیری فازی با استفاده از الگوریتم ژنتیک به روش پیتزبورگ طراحی شده است. ابتدا ویژگی‌های عددی از یک دیتاست فازی‌سازی می‌شوند. سپس، الگوریتم ژنتیک برای تولید قوانینی که می‌توانند داده‌ها را به دسته‌های malignant و benign طبقه‌بندی کنند، اجرا می‌شود.

الگوریتم قوانین اولیه را تولید می‌کند، آن‌ها را بهبود می‌دهد، و بهترین کروموزوم را برای طبقه‌بندی داده‌ها انتخاب می‌کند.

## ۱-۲-۷ توابع کد

```
import numpy as np
import pandas as pd
import random
from sklearn.metrics import accuracy_score, mean_squared_error, roc_auc_score

def generate_rule(features, output_labels):
    rule_conditions = []
    selected_features = random.sample(features, 3)
    for feature in selected_features:
        rule_conditions.append({
            "feature": feature,
            "fuzzy": random.choice(["low", "medium", "high"]),
        })
    output = random.choice(output_labels)
    return {"conditions": rule_conditions, "output": output}

def initialize_population(pop_size, num_rules, features, output_labels):
    population = []
```

```

    for _ in range(pop_size):
        rules = [generate_rule(features, output_labels) for _ in range(num_rules)]
        population.append(rules)
    return population

def evaluate_rule(rule, data, labels):
    correct_predictions = 0
    for idx, data_point in data.iterrows():
        match = all(
            data_point[cond["feature"]] == cond["fuzzy"]
            for cond in rule["conditions"]
        )
        if match and rule["output"] == labels.iloc[idx]:
            correct_predictions += 1
    return correct_predictions / len(data)

def evaluate_population(population, data, labels):
    fitness_scores = []
    for rules in population:
        fitness = np.mean([evaluate_rule(rule, data, labels) for rule in rules])
        fitness_scores.append(fitness)
    return fitness_scores

def crossover(parent1, parent2):
    point = random.randint(1, len(parent1) - 1)
    child1 = parent1[:point] + parent2[point:]
    child2 = parent2[:point] + parent1[point:]
    return child1, child2

def mutate(rules, mutation_rate, features, output_labels):
    for rule in rules:
        if random.random() < mutation_rate:
            rule["conditions"][random.randint(0, len(rule["conditions"]) - 1)]["fuzzy"] = random.choice([
                "low", "medium", "high"
            ])
        if random.random() < mutation_rate:
            rule["output"] = random.choice(output_labels)
    return rules

def genetic_algorithm(data, labels, features, output_labels, pop_size=20,
num_rules=10, num_generations=100, mutation_rate=0.4):
    population = initialize_population(pop_size, num_rules, features,
output_labels)
    best_fitness = 0
    best_solution = None

    for generation in range(num_generations):

```

```

fitness_scores = evaluate_population(population, data, labels)
sorted_indices = np.argsort(fitness_scores)[::-1]

if fitness_scores[sorted_indices[0]] > best_fitness:
    best_fitness = fitness_scores[sorted_indices[0]]
    best_solution = population[sorted_indices[0]]

print(f"Generation {generation + 1}: Best Fitness = {best_fitness}")

best_rule_set = population[sorted_indices[0]]
print("Best Rule Set:")
for rule in best_rule_set:
    conditions = " AND ".join([
        f"{cond['feature']} IS {cond['fuzzy']}" for cond in
rule["conditions"]])
    )
    print(f"IF {conditions}, THEN OUTPUT IS {rule['output']}")

new_population = []
for i in range(0, pop_size, 2):
    parent1 = population[sorted_indices[i]]
    parent2 = population[sorted_indices[i + 1]]
    child1, child2 = crossover(parent1, parent2)
    new_population.extend([mutate(child1, mutation_rate, features,
output_labels), mutate(child2, mutation_rate, features, output_labels)])
population = new_population

return best_solution, best_fitness

data = pd.read_csv("data.csv")
data.rename(columns={'concave points_mean': 'concave_points_mean'}, inplace=True)

labels = data["diagnosis"].map({'B': "benign", "M": "malignant"})
data = data.drop(columns=["diagnosis"])

features = [
    "radius_mean",
    "texture_mean",
    "perimeter_mean",
    "area_mean",
    "smoothness_mean",
    "compactness_mean",
    "concavity_mean",
    "concave_points_mean",
]
data = data[features]

def fuzzify(value):

```

```

if value < 0.33:
    return "low"
elif value < 0.66:
    return "medium"
else:
    return "high"

for feature in features:
    data[feature] = data[feature].apply(lambda x: fuzzify(x / data[feature].max()))

output_labels = ["benign", "malignant"]
best_solution, best_fitness = genetic_algorithm(data, labels, features,
output_labels)

print("Best Solution:")
for rule in best_solution:
    conditions = " AND ".join(
        [f"{cond['feature']} IS {cond['fuzzy']}" for cond in rule["conditions"]])
    print(f"IF {conditions}, THEN OUTPUT IS {rule['output']}")

print(f"Best Fitness: {best_fitness}")

final_predictions = []
for _, data_point in data.iterrows():
    prediction = None
    for rule in best_solution:
        match = all(
            data_point[cond['feature']] == cond['fuzzy']
            for cond in rule['conditions'])
        if match:
            prediction = 1 if rule['output'] == 'malignant' else 0
            break
    final_predictions.append(prediction if prediction is not None else 0)

final_predictions = ['malignant' if pred == 1 else 'benign' for pred in
final_predictions]

accuracy = accuracy_score(labels, final_predictions)
print(f"Accuracy: {accuracy:.4f}")

mse = mean_squared_error(labels.map({'benign': 0, 'malignant': 1}), [1 if pred ==
'malignant' else 0 for pred in final_predictions])
print(f"Mean Squared Error (MSE): {mse:.4f}")

rmse = np.sqrt(mse)
print(f"Root Mean Squared Error (RMSE): {rmse:.4f}")

```

```

auc = roc_auc_score(labels.map({'benign': 0, 'malignant': 1}), [1 if pred ==
'malignant' else 0 for pred in final_predictions])
print(f"Area Under the Curve (AUC): {auc:.4f}")

```

بر اساس ۱۰۰ نسل این الگوریتم بهترین کروموزم به دست آمده شامل این ۱۰ قوانین است:

Best Solution:

IF perimeter\_mean IS medium AND concave\_points\_mean IS low AND concavity\_mean IS low, THEN  
OUTPUT IS malignant

IF radius\_mean IS medium AND compactness\_mean IS medium AND concave\_points\_mean IS  
medium, THEN OUTPUT IS malignant

IF area\_mean IS high AND compactness\_mean IS low AND concavity\_mean IS low, THEN OUTPUT IS  
malignant

IF concave\_points\_mean IS medium AND perimeter\_mean IS low AND compactness\_mean IS low,  
THEN OUTPUT IS malignant

IF texture\_mean IS high AND radius\_mean IS low AND smoothness\_mean IS high, THEN OUTPUT IS  
malignant

IF perimeter\_mean IS medium AND concavity\_mean IS low AND area\_mean IS high, THEN OUTPUT  
IS malignant

IF radius\_mean IS high AND perimeter\_mean IS low AND concave\_points\_mean IS medium, THEN  
OUTPUT IS malignant

IF concave\_points\_mean IS high AND perimeter\_mean IS high AND radius\_mean IS high, THEN  
OUTPUT IS malignant

IF perimeter\_mean IS medium AND area\_mean IS low AND texture\_mean IS high, THEN OUTPUT IS  
malignant

IF radius\_mean IS medium AND perimeter\_mean IS high AND compactness\_mean IS medium, THEN  
OUTPUT IS malignant

## ۷-۲-۲ ارزیابی عملکرد

```

accuracy = accuracy_score(labels, final_predictions)
print(f"Accuracy: {accuracy:.4f}")

mse = mean_squared_error(labels, final_predictions)
print(f"Mean Squared Error (MSE): {mse:.4f}")

rmse = np.sqrt(mse)

```

```
print(f"Root Mean Squared Error (RMSE) : {rmse:.4f}")

auc = roc_auc_score(labels, final_predictions)
print(f"Area Under the Curve (AUC) : {auc:.4f}")
```

نتایج به دست آمده به شکل زیر است:

Accuracy: 0.3146

Mean Squared Error (MSE): 0.6854

Root Mean Squared Error (RMSE): 0.8279

Area Under the Curve (AUC): 0.3791

## فصل ۸

سیستم فازی نوع ۲ و مقایسه با فازی نوع اول

## ۸-۱ فازی نوع ۲

فازی نوع ۲ نسخه پیشرفته‌ای از فازی نوع ۱ است که برای مدیریت عدم قطعیت‌های بیشتر طراحی شده است. در این سیستم، به جای مقدار دقیق درجه عضویت، یک بازه از مقادیر ممکن تعریف می‌شود. این بازه که به آن "اثر عدم قطعیت (FOU)" گفته می‌شود، کمک می‌کند تا سیستم در شرایطی که داده‌ها دارای ابهام یا نویز هستند، بهتر تصمیم‌گیری کند. فازی نوع ۲ در کاربردهایی مانند پزشکی و سیستم‌های پیچیده استفاده می‌شود.

## ۸-۲ توضیحات کد

۱. آماده‌سازی داده‌ها : داده‌ها از فایل بارگذاری شده، مقیاس‌بندی می‌شوند و به دو مجموعه آموزشی و تست تقسیم می‌شوند.
۲. محاسبه عضویت فازی نوع ۲: تابع `fuzzify_type2` برای هر ویژگی مقدار عضویت حد پایین و بالا را محاسبه می‌کند.
۳. ترکیب عضویت‌ها : تابع `apply_fuzzy_rules` از عضویت‌های پایین و بالا برای همه ویژگی‌ها یک خروجی نهایی فازی می‌سازد.
۴. طبقه‌بندی بر اساس آستانه: خروجی‌های فازی با مقایسه با یک آستانه (`threshold`) به دسته‌های مثبت (+) یا منفی (-) طبقه‌بندی می‌شوند.

## ۸-۲-۱ کد توابع

```
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score, confusion_matrix, roc_auc_score,
roc_curve
from sklearn.preprocessing import MinMaxScaler
import matplotlib.pyplot as plt
import seaborn as sns

data = pd.read_csv("data.csv")
data.rename(columns={'concave points_mean': 'concave_points_mean'}, inplace=True)
data = data.drop(['id', 'Unnamed: 32'], axis=1)
data['diagnosis'] = data['diagnosis'].map({'M': 1, 'B': 0})
```

```

X = data.drop(['diagnosis'], axis=1)
y = data['diagnosis']

scaler = MinMaxScaler()
X_scaled = pd.DataFrame(scaler.fit_transform(X), columns=X.columns)

X_train, X_test, y_train, y_test = train_test_split(X_scaled, y, test_size=0.3,
random_state=42)

def fuzzify_type2(value, bounds, uncertainty=0.1):
    lower_bound, upper_bound = bounds
    lower_membership = max(0, min(1, (upper_bound - (value - uncertainty)) /
(upper_bound - lower_bound)))
    upper_membership = max(0, min(1, ((value + uncertainty) - lower_bound) /
(upper_bound - lower_bound)))
    return lower_membership, upper_membership

def apply_fuzzy_rules(row, feature_bounds):
    results = []
    for feature, bounds in feature_bounds.items():
        value = row[feature]
        lower, upper = fuzzify_type2(value, bounds)
        low_output = lower * 0.3
        high_output = upper * 0.7
        results.append((low_output + high_output) / 2)
    return np.mean(results)

feature_bounds = {feature: (X_train[feature].min(), X_train[feature].max()) for
feature in X_train.columns}

X_train['fuzzy_output'] = X_train.apply(lambda row: apply_fuzzy_rules(row,
feature_bounds), axis=1)
X_test['fuzzy_output'] = X_test.apply(lambda row: apply_fuzzy_rules(row,
feature_bounds), axis=1)

threshold = (X_train['fuzzy_output'].mean() + X_train['fuzzy_output'].median()) / 2

X_train['fuzzy_class'] = X_train['fuzzy_output'].apply(lambda x: 1 if x > threshold
else 0)
X_test['fuzzy_class'] = X_test['fuzzy_output'].apply(lambda x: 1 if x > threshold
else 0)

```

## ۸-۲-۲ ارزیابی عملکرد

```
train_accuracy = accuracy_score(y_train, X_train['fuzzy_class'])
test_accuracy = accuracy_score(y_test, X_test['fuzzy_class'])
roc_auc = roc_auc_score(y_test, X_test['fuzzy_output'])

print(f"Training Accuracy: {train_accuracy:.2f}")
print(f"Test Accuracy: {test_accuracy:.2f}")
print(f"ROC AUC: {roc_auc:.2f}")
```

نتایج به دست آمده به این شکل است:

Training Accuracy: 0.86

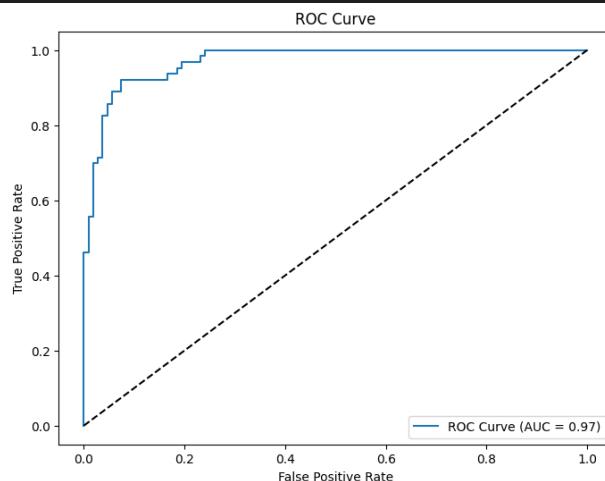
Test Accuracy: 0.87

ROC AUC: 0.97

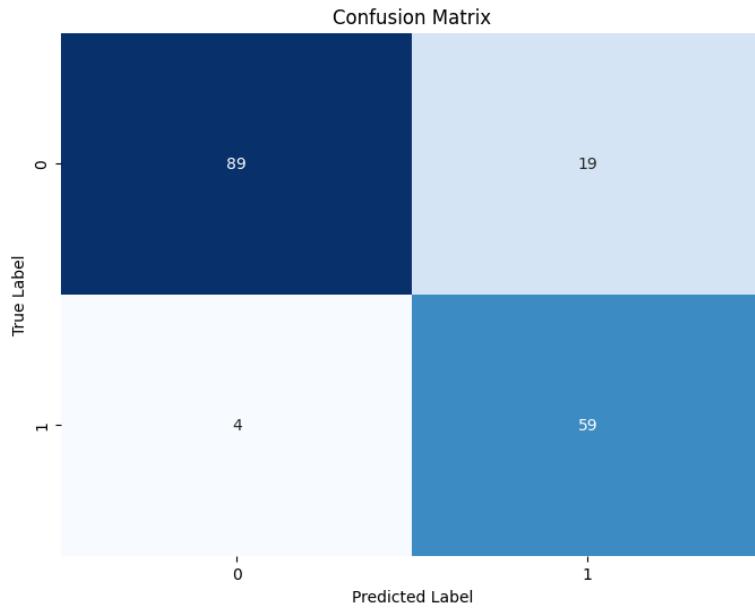
با استفاده از کد ماتریس سردرگمی و نمودار ROC نمایش داده شده است:

```
plt.figure(figsize=(8, 6))
sns.heatmap(conf_matrix, annot=True, fmt="d", cmap="Blues", cbar=False)
plt.title("Confusion Matrix")
plt.xlabel("Predicted Label")
plt.ylabel("True Label")
plt.show()

fpr, tpr, _ = roc_curve(y_test, X_test['fuzzy_output'])
plt.figure(figsize=(8, 6))
plt.plot(fpr, tpr, label=f"ROC Curve (AUC = {roc_auc:.2f})")
plt.plot([0, 1], [0, 1], 'k--')
plt.xlabel("False Positive Rate")
plt.ylabel("True Positive Rate")
plt.title("ROC Curve")
plt.legend()
plt.show()
```



شکل ۱-۸ ماتریس سردرگمی



شکل ۸-۲ ماتریس سردرگمی

### ۸-۳ مقایسه فازی نوع ۱ و نوع ۲

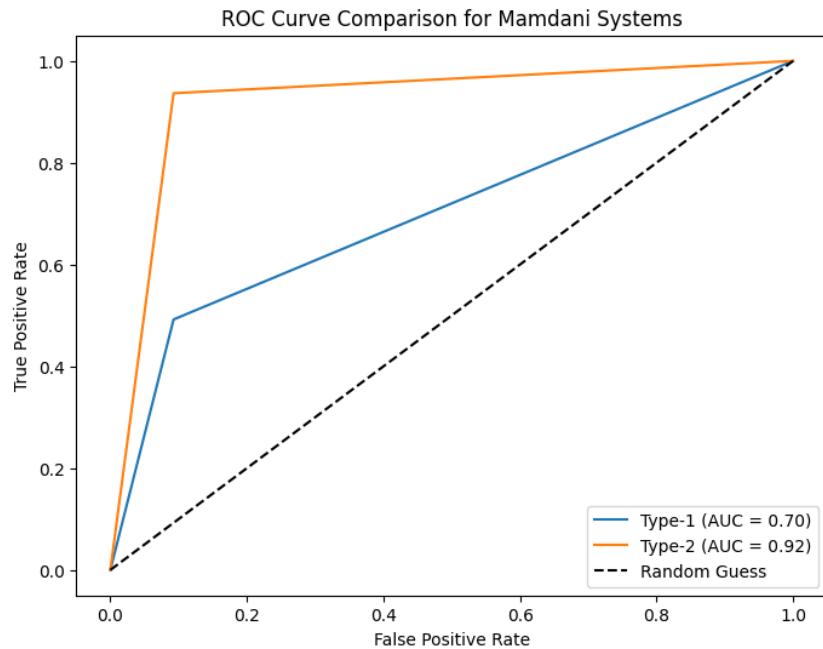
به منظور ارزیابی ۲ مدل، روی داده های تست ارزیابی صورت گرفته است. که نتیجه به این شکل است:

```

plt.figure(figsize=(8, 6))
for system, data in metrics.items():
    plt.plot(data['fpr'], data['tpr'], label=f'{system} (AUC = {data["roc_auc"]:.2f})')
plt.plot([0, 1], [0, 1], 'k--', label="Random Guess")
plt.xlabel("False Positive Rate")
plt.ylabel("True Positive Rate")
plt.title("ROC Curve Comparison for Mamdani Systems")
plt.legend(loc="lower right")
plt.show()

# Print Metrics
for system, data in metrics.items():
    print(f'{system} Accuracy: {data["accuracy"]:.2f}')
    print(f'{system} AUC: {data["roc_auc"]:.2f}')

```



سیستم فازی نوع ۱ در مقایسه با سیستم فازی نوع ۲ عملکرد بدتری در جداسازی نمونه‌های خوش خیم و بدخیم دارد و مقدار AUC کمتری نشان می‌دهد. در مقابل، سیستم فازی نوع ۲ با استفاده از محدوده‌های عدم قطعیت در عضویت‌ها، انعطاف‌پذیری بیشتری داشته و منحنی ROC آن به گوشه بالا-چپ نزدیک‌تر است که نشان‌دهنده دقیق‌تر در پیش‌بینی نمونه‌ها است. مقدار AUC بالاتر (مانند ۰,۹۷) نشان می‌دهد که سیستم نوع ۲ در مدیریت داده‌های پیچیده و جداسازی دقیق‌تر عملکرد بهتری دارد.

ممnon از توجه شما

پریا افشاری پور

