

**Lógica Fuzzy para Reconhecimento de Padrões e Classificação para Smart Grid**

**Fuzzy Logic for Pattern Recognition and Classification to Smart Grid**

DOI:10.34117/bjdv6n12-293

Recebimento dos originais: 14/11/2020

Aceitação para publicação: 14/12/2020

**Wyrllen Everson de Souza**

Doutor

Instituição: Universidade Tecnológica Federal do Paraná

Endereço completo: R. Rosalina Maria Ferreira, 1233 - Vila Carola, Campo Mourão - PR, 87301-899

E-mail: wyrllen.souza@gmail.com

**Magda Cardoso Mantovani**

Doutor

Instituição: Universidade Tecnológica Federal do Paraná

Endereço completo: R. Rosalina Maria Ferreira, 1233 - Vila Carola, Campo Mourão - PR, 87301-899

E-mail: magdacm@utfpr.edu.br

**Roberto Ribeiro Neli**

Doutor

Instituição: Universidade Tecnológica Federal do Paraná

Endereço completo: R. Rosalina Maria Ferreira, 1233 - Vila Carola, Campo Mourão - PR, 87301-899

E-mail: rneli@yahoo.com.br

**Daniela Cavalheiro**

Graduada

Instituição: Universidade Tecnológica Federal do Paraná

Endereço completo: R. Rosalina Maria Ferreira, 1233 - Vila Carola, Campo Mourão - PR, 87301-899

E-mail: daniela.cavalheiro@gmail.com

**Alexandre Rasi Aoki**

Formação: Doutor

Instituição: Universidade Federal do Paraná

Endereço completo: Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000

E-mail: rneli@yahoo.com.br

**Anselmo Chaves Neto**

Doutor

Instituição: Universidade Federal do Paraná

Endereço completo: Av. Cel. Francisco H. dos Santos, 100 - Jardim das Américas, Curitiba - PR, 81530-000

E-mail: anselmo@ufpr.br

**RESUMO**

O presente trabalho tem como objetivo apresentar uma aplicação em Lógica Fuzzy para avaliar informações de métodos de Reconhecimento e Classificação de Padrões aplicados a medidas de Qualidade de Energia Elétrica em centros de medição inteligentes. A Lógica Fuzzy é responsável por gerenciar o resumo dos resultados apresentados por diversos métodos de Padrões de Reconhecimento e Classificação e, assim, pode sintetizar e integrar os desempenhos das técnicas, melhorando o desempenho do sistema. Desta forma, um sistema de Lógica Fuzzy pode inferir uma classificação potencializando os pontos fortes individuais de cada técnica para suprir as deficiências específicas em algum erro de classificação obtido por uma dada técnica é apresentada. Para validação, a arquitetura do sistema foi aplicada a um problema de qualidade de energia de transformadores de distribuição.

**Palavra-chaves:** Lógica Fuzzy, Reconhecimento e Classificação de Padrões, Distorções Harmônicas de Tensão.

**ABSTRACT**

The present work aims to present a Fuzzy Logic application to evaluate information from methods of Pattern Recognition and Classification applied to Power Quality measurements from smart metering center. Fuzzy Logic is responsible for managing the summary of results presented by several methods of Recognition and Classification Patterns and thus can synthesize and integrate the performances of techniques, improving system performance. This way, a system of Fuzzy Logic can infer a classification leveraging the individual strengths of each technique to meet the specific deficiencies in some misclassification obtained by a given technique is presented. For validation, the architecture of the system was applied to a problem of power quality of distribution transformers.

**Keyword:** Fuzzy Logic, Pattern Recognition and Classification, Voltage Harmonic Distortion.

**1 INTRODUÇÃO**

A próxima geração de sistemas de distribuição, conforme descrito por (WOLLENERG E AMIM, 2005) renovou o interesse em integrar todos os ativos do sistema, incluindo equipamentos de rede, consumidores e fontes de geração distribuída sob a mesma infraestrutura para medição, controle e operação. Um grande desafio para alcançar a funcionalidade total das redes inteligentes diz respeito ao desenvolvimento de um centro de medição inteligente. Essa dificuldade inclui definir o papel e as responsabilidades daquela entidade, por exemplo, citado por (ZHANG, LI e BHATT, 2010) apresenta uma visão dos centros de controle, monitoramento e análise para redes inteligentes.

Além disso, nos últimos anos, a Qualidade de Energia Elétrica (QEE) teve um crescente interesse para as Empresas do Sistema de Distribuição e Operadoras do Sistema de Transmissão devido à queda nos índices de confiabilidade e serviço. Este foi um dos principais impulsionadores para direcionar os investimentos para as Smart Grid.

Espera-se que com a implementação das Smart Grid, as concessionárias de distribuição demandem uma quantidade muito maior de informações para a operação e controle da rede segundo (HEYDT, 2010). O presente trabalho tem como objetivo apresentar uma aplicação da Lógica Fuzzy apresentada

por (ZADEH, 1965) para avaliar informações de métodos de Reconhecimento e Classificação de Padrões aplicados a medições de Qualidade de Energia Elétrica em centros de medição inteligente.

O objetivo geral desse trabalho é apresentar um modelo de Lógica Fuzzy capaz de gerenciar o resumo dos resultados apresentados por diversos métodos de Reconhecimento e Classificação de Padrões e, assim, pode sintetizar e integrar os desempenhos das técnicas, melhorando o desempenho do sistema. Desta forma, um sistema de Lógica Fuzzy pode inferir uma classificação potencializando os pontos fortes individuais de cada técnica para suprir as deficiências específicas em algum erro de classificação obtido por uma dada técnica. Para validação, o sistema fuzzy foi aplicado a um problema de Qualidade de Energia Elétrica de transformadores da rede de distribuição.

Para tanto são apresentados os métodos de Reconhecimento e Classificação de Padrões utilizados no trabalho além da metodologia de Lógica Fuzzy aplicada no gerenciamento dos resultados.

## **2 MATERIAL E MÉTODOS**

### **2.1 RECONHECIMENTO E CLASSIFICAÇÕES DE PADRÕES**

De acordo com (JOHNSON e WICHERN, 1998), do ponto de vista estatístico, o desenvolvimento de regras para reconhecimento e classificação de padrões para duas populações é baseado em quatro métodos principais: função discriminante linear de Fisher, pontuação discriminante quadrática, regressão logística e método k-médias. Além disso, a análise discriminante é uma técnica multivariada com o objetivo de separar o conjunto de dois objetos distintos e alocar novos objetos em conjuntos previamente definidos. O uso de técnicas multivariadas para discriminação e classificação tem as seguintes intenções.

1. Descrição algébrica ou gráfica das características distintas do objeto de várias populações conhecidas, a fim de encontrar o valor discriminante que leva à separação máxima das populações.

2. Objetos de cluster em duas ou mais classes determinadas tentando encontrar uma regra a ser usada para a alocação ideal de um novo objeto. Uma função de separação pode ser usada para alocação de objetos, assim como uma regra de alocação pode sugerir um procedimento discriminatório.

#### **2.1.1 Regressão Logística**

A Regressão Logística consiste em conectar, por meio de um modelo, o sinal de saída para influenciar os fatores de um evento. Para atender a este critério, o modelo logístico linear múltiplo deve ter o seguinte aspecto.

Considere uma variável aleatória  $y$  (dicotômica) e um vetor de dimensão  $p$   $X'=[X_1, X_2, \dots, X_p]$  composto de variáveis aleatórias independentes. Tomando  $n$  observações independentes de  $Y$  e  $X_i$ , com  $i = 1, 2, \dots, p$ , podemos escrever um modelo de regressão logística como:

$$P(y) = \frac{1}{1 + e^{-\mu}}$$

com  $\mu = \beta_0 + \beta_1 x_1 + \dots + \beta_{p-1} x_{p-1} = \underline{x} \underline{\beta}$ .

Onde  $y$  é o valor dicotômico em função do vetor  $x_1, x_2, \dots, x_{p-1}$ ,  $P(y)$  é a probabilidade de ocorrer  $y$ ,  $x_1, x_2, \dots, x_{p-1}$  são os fatores do modelo e  $\beta_0, \beta_1, \dots, \beta_{p-1}$  são os parâmetros ajustados do modelo.

### 2.1.2 Análise Discriminante Quadrática

Considere um vetor aleatório  $\underline{X}$  de uma população normal multivariada, onde temos o vetor de médias  $\underline{\mu}_i$  e a matriz de covariância  $\Sigma_i$ , desta forma, temos:

$$f_i(\underline{X}) = \frac{1}{(2\pi)^{p/2} |\Sigma_i|} \exp \left[ -\frac{1}{2} (\underline{X} - \underline{\mu}_i)' \Sigma_i (\underline{X} - \underline{\mu}_i) \right]$$

onde  $i=1, 2, \dots, g$ ;  $\underline{\mu}_i = E(\underline{x} | \Pi_i)$ , e  $V(\underline{x} | \Pi_i) = \Sigma_i$ .

Os escores da discriminação quadrática é definido por  $d_i^Q$  para as populações  $\Pi_i$  assim:

$$d_i^Q(\underline{X}) = \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (\underline{X} - \underline{\mu}_i)' \Sigma_i^{-1} (\underline{X} - \underline{\mu}_i) + \ln p_i, i = 1, 2, \dots, g$$

onde  $i=1, 2, \dots, g$ .

### 2.1.3 Redes Neurais

De acordo com [6], as redes neurais são definidas como: Uma rede neural é um processador massivamente distribuído em paralelo, composto por unidades de processamento simples, que tem uma propensão natural para armazenar conhecimento experiencial e torná-lo disponível para uso. Ele se assemelha ao cérebro em dois aspectos:

1. O conhecimento que é adquirido pela rede em seu ambiente por meio de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.

Assim, uma rede neural pode ser definida como um framework computacional que visa possibilitar a implementação de modelos matemáticos que representam a forma como o cérebro

humano processa as informações que adquire.

## 2.2 MONITORAMENTO DAS DISTORÇÕES HARMÔNICAS DE TENSÃO

O banco de dados, utilizado em modelos de classificação, foi obtido por meio de uma campanha de monitoramento de amostragem cobrindo todos os tipos de transformadores de distribuição que operam em uma concessionária de distribuição do sul do Brasil. A campanha de monitoramento tem como objetivo mapear os níveis de distorção harmônica de tensão no sistema de distribuição de baixa tensão.

Foram monitorados 359 transformadores de concessionária de distribuição. Esses equipamentos foram selecionados em um universo de cerca de 320.000 transformadores de distribuição considerando a capacidade instalada regional de transformadores e o número de consumidores por transformador na área urbana.

A parametrização do equipamento de monitoramento e o tempo de monitoramento de cada transformador de distribuição foram estabelecidos pela Agência Nacional de Energia Elétrica (ANEEL) considerando 10 minutos para o tempo de integração durante sete dias consecutivos.

Foram analisados os níveis máximo, mínimo e médio da Distorção Harmônica de Tensão (DHT), bem como, desvio padrão e  $P_{95\%}$  para cada transformador monitorado. Porém, para o modelo estatístico, utilizamos apenas  $P_{95\%}$  da DHT com características técnicas dos transformadores de distribuição e dados de consumo de energia. Foi utilizada uma regulamentação brasileira para avaliar o valor máximo de DHT de tensão e os níveis de tensão permitidos em redes de distribuição de baixa tensão segundo a ANEEL.

Os métodos de Padrões de Reconhecimento e Classificação foram usados para separar os transformadores de distribuição em dois grupos, um com DHT menor ou igual a 6% e outro com DHT maior que 6% dados pela NOS.

O limite de DHT considerado para estimativa dos modelos estatísticos (6%) foi obtido junto ao ONS (Power System National Operator) Network Procedures do Brasil. A Tabela 5 mostra os limites estabelecidos por esta Instituição.

Os grupos foram separados por seu valor máximo de THD de voltagem, como:

- Grupo 1: variável dependente com  $P_{95\%}$  da tensão DHT acima de 6% em qualquer fase do transformador;
- Grupo 2: variável dependente com  $P_{95\%}$  da tensão DHT menor ou igual a 6% em todas as fases do transformador.

**2.2.1 Características Técnicas dos Transformadores e Dados de Uso de Energia**

Com base nos resultados do monitoramento, buscou-se parâmetros da rede de energia que podem afetar o comportamento da distorção harmônica de tensão em redes de distribuição de baixa tensão para fornecer reconhecimento e desenvolvimento de modelos de padrões de classificação. Assim, foram considerados fatores determinantes para a degradação da forma de onda da tensão em redes de distribuição de baixa tensão as características da carga e dos curto-circuitos de potência no ponto de conexão.

As características de carga foram divididas em consumo médio mensal de energia para cada classe de consumidor conectada no transformador de distribuição. Além disso, características do equipamento foram utilizadas para valorizar os modelos. A Tabela 1 mostra as características utilizadas.

TABELA 1 - CARACTERÍSTICAS TÉCNICAS E DADOS DE USO DE ENERGIA

Características	Descrição
Superintendência Regional	(Norte, Leste, Centro, Oeste e Nordeste)
Operacional	Urbano ou Rural
Tensão Primária	34,500V ou 13,800V
Potência (Potência Nominal do Transformador (kVA))	112.5, 75, 45, 30, 15, 10 ou 5
Fases	1 ou 3
Número de Consumidores	Número de consumidores conectados ao transformador de distribuição
Consumo[kWh]	Consumo médio mensal de energia em cada classe de consumidor: Residencial 0/50 kWh Residencial 50/100 kWh Residencial 100/150 kWh Residencial 150/200 kWh Residencial 200/300 kWh Residencial 300/500 kWh Residencial 500/1000 kWh Residencial >1000 kWh Comércio e Poder Publico Industrial Rural Iluminação Pública

**2.3 LÓGICA FUZZY**

Durante as últimas décadas, tem havido um crescimento considerável do interesse nos problemas de Reconhecimento e Classificação de Padrões, com o conseqüente aumento da necessidade de métodos para uso no desenvolvimento de sistemas nesta área. Na engenharia de energia, vários estudos que incluem métodos de Reconhecimento e Classificação de Padrões, em muitos trabalhos são feitas comparações de métodos a fim de encontrar um método melhor para o problema estudado.

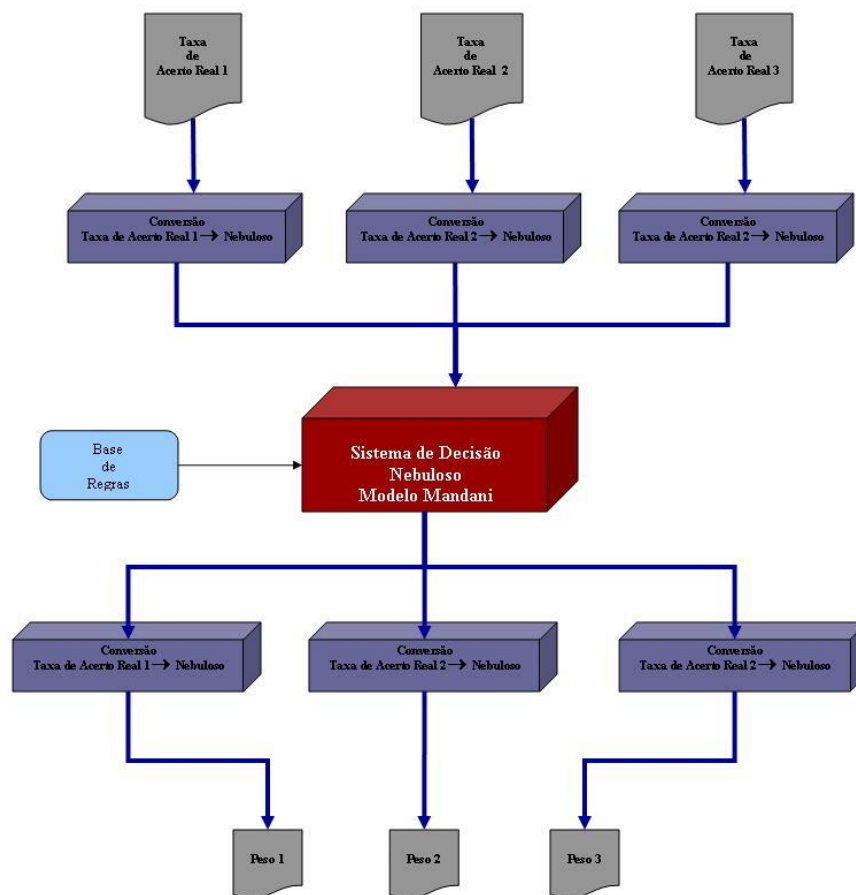
(Souza, Aoki e Chaves- Neto, 2009) apresenta o desenvolvimento de um modelo estatístico computacional para estimar a distorção harmônica de tensão a partir das características de transformadores e consumidores de distribuição utilizando técnicas de Análise Multivariada e Conjuntos Rough Sets.

No entanto, em geral, as técnicas são aplicadas separadamente e comparadas a fim de usar o melhor. Assim, a lógica fuzzy não apenas gerencia as técnicas como integra e sintetiza o desempenho das técnicas, melhorando o desempenho do sistema.

A primeira etapa foi a aplicação dos métodos de reconhecimento e classificação de padrões ao conjunto de dados para testar a eficiência de cada método. Para isso foi utilizada a técnica de leave-one-out (Lachenbruch, 1975) para uma taxa real de erro na classificação dos grupos.

Para gerenciar as técnicas de reconhecimento e classificação de padrões foi utilizado o modelo de Lógica Fuzzy utilizado foi um modelo Mamdani, apresentado na figura 1.

Figura 1. Modelo Mandani




Fonte: Autoria Própria(2020)

O modelo Mamdani contendo três variáveis numéricas de entrada. Variáveis de entrada contendo os valores da taxa de erro real de cada reconhecimento de método e padrões de classificação.

- Taxa de erro real - 1: Regressão logística
- Taxa de erro real - 2: Pontuação Discriminante Quadrática
- Taxa de erro real - 3: Rede Neural

As funções de pertinência desenvolvidas para as variáveis de entrada são mostradas na figura 2.



Fonte: Autoria Própria (2020)

As variáveis de entrada foram divididas em quatro subconjuntos nebulosos considerando uma faixa de valores possíveis no intervalo de  $[0,1]$ . Esses subconjuntos foram definidos, conforme descrito a seguir:

- Ruim: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0, 0, 0.50, 0.60]$ ;
- Bom: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0.55, 0.60, 0.70, 0.75]$ ;
- Muito Bom: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0.70, 0.75, 0.85, 0.90]$ ;
- Excelente: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0.85, 0.90, 1, 1]$ ;


Foram utilizadas três variáveis de saída contendo os pesos para cada classificação obtida pelos métodos de reconhecimento e padrões de classificação.

- Pesos - (W1): Regressão Logística
- Pesos - (W2): Pontuação Quadrática Discriminante
- Pesos - (W3): Rede Neural

As funções de pertinência desenvolvidas para as variáveis de saída são mostradas na figura 3.



Figura 3 – Funções das Variáveis de Saída



Fonte: Autoria Própria (2020)

As variáveis de saída foram divididas em cinco subconjuntos nebulosos considerando uma faixa de valores possíveis no intervalo de  $[0,1]$ . Esses subconjuntos foram definidos, conforme descrito a seguir:

- Taxa de Acerto Muito Baixa: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0, 0, 0.10, 0.15]$ ;
- Taxa de Acerto Baixa: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0.10, 0.15, 0.35, 0.45]$ ;
- Taxa de Acerto Médio: escolheu-se uma função triangular com as seguintes parametrizações  $[0.40, 0.50, 0.60]$ ;
- Taxa de Acerto Alto: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0.55, 0.60, 0.80, 0.85]$ ;
- Taxa de Acerto Multo Alto: escolheu-se uma função trapezoidal com as seguintes parametrizações  $[0.80, 0.85, 1, 1]$ ;

Foram desenvolvidas 64 regras para a base de conhecimento, a seguir é apresentado um exemplo dessas regras:

<Se “Taxa Real de Acerto – 1 ” for “Bom” e Taxa Real de Acerto – 2 ” for “Muito Bom” e Taxa Real de Acerto – 3 ” for “Ruim”> então < “Peso – 1” é “Médio” e “Peso – 2” é “Alto” e “Peso – 3.” é “Muito Baixa”.>

Com base nos pesos das variáveis de saída apresentadas, é possível criar uma Função de Classificação como:

$$F.C. = \bar{W}_1 R_1 + \bar{W}_2 R_2 + \bar{W}_3 R_3$$

- $\bar{W}_i = \frac{W_i}{\sum W_i}$
- $R_1$  é a classificação da nova observação pelo Agente Especialista 1 – Regressão Logística;
- $R_2$  é a classificação da nova observação pelo Agente Especialista 2 – Escore Quadrática;
- $R_3$  é a classificação da nova observação pelo Agente Especialista 1 – Redes Neurais.

E a Regra de Classificação é dada por:

$$SE \begin{cases} R.F.C. > c & \text{Nova Observação Grupo 1} \\ R.F.C. < c & \text{Nova Observação Grupo 0} \end{cases}$$

onde  $c$  é o valor da faixa de corte do sistema (valor adotado para classificação igual a 0,5).

### 3 RESULTADOS E DISCUSSÕES

Para a validação da lógica fuzzy no gerenciamento dos resultados dos padrões de reconhecimento e classificação, foi utilizado o método leave-one-out.

Os resultados da aplicação da lógica fuzzy na gestão da síntese dos resultados dos métodos de reconhecimento e padrões de classificação na classificação da base de dados são apresentados a seguir:

Tabela 2 – Resultado da Regressão Logística

Método	Classificação do Modelo	
	Grupo 1	Grupo 2
Classificação Real	Grupo 1	237 (84.34%)
	Grupo 2	44 (15.65%)
	Grupo 1	56 (71.79%)
	Grupo 2	22 (28.20%)

FONTE: AUTORIA PRÓPRIA (2020)

Tabela 3 – Resultado da Análise Discriminante

Método	Classificação do Modelo	
	Grupo 1	Grupo 2
Classificação Real	Grupo 1	180 (64.05%)
	Grupo 2	101 (35.94%)
	Grupo 1	26 (33.33%)
	Grupo 2	52 (66.67%)

Fonte: Autoria Própria (2020)

Tabela 4 – Resultado da Rede Neural

Método	Classificação do Modelo	
	Grupo 1	Grupo 2
Classificação Real	Grupo 1	273 (97.15%)
	Grupo 2	8 (2.85%)
	Grupo 1	53 (67.94%)
	Grupo 2	25 (32.05%)

Fonte: Autoria Própria (2020)

Baseado na previsão de cada modelo podemos sumarizar os resultados na tabela 5.

Tabela 5 – Resultados dos Métodos Aplicados

Métodos	Erro I	Erro II	Erro Total
Regressão Logística	15.65%	71.79%	27.85%
Análise Discriminante	35.94%	33.33%	35.37 %
Rede Neural	2.85%	67.94%	16.99%

Fonte: Aatoria Própria (2020)

onde:

- Erro I: transformadores do grupo 2 classificados no grupo 1;
- Erro II: transformadores do grupo 1 classificado no grupo 2;
- Erro Total: Erro total dos modelos.

Baseado na Tabela 5 podemos destacar os seguintes pontos:

- Todos os métodos apresentaram resultados satisfatórios no reconhecimento e classificação de padrões;
- A Rede Neural teve o menor Erro I (2.85%), mas em contrapartida teve o pior Erro II (67.94%).
- A Regressão Logística também obteve um Erro I (15.65%) baixo, porém obteve um Erro II (71.79%) alto.
- A Análise discriminante teve um resultado satisfatório nos dois erros, Erro II (33.33%), Erro I (35.94%).

Todos os métodos apresentaram resultados satisfatórios, porém nenhum método foi o melhor em todos os aspectos, portanto aplicou-se a lógica fuzzy para gerenciar e sintetizar os resultados dos métodos de reconhecimento e classificação. A aplicação da lógica fuzzy apresentou os seguintes resultados:

Tabela 6 – Lógica Fuzzy aplicado nos Métodos de REconhecimento e Classificação de Padrões

Métodos	Classificação do Modelo	
	Grupo 1	Grupo 2
Classificação Real	Grupo 1	273 (97.15%)
	Grupo 2	8 (2.85%)
		22 (28.20%)
		56 (71.80%)

Fonte: Aatoria Própria (2020)

Com a aplicação da lógica fuzzy observa-se uma melhora significativa tanto na redução do erro II (28,20%), no melhor caso foi de 33,33% com a aplicação do escore discriminante quadrático.

Para o erro I a lógica fuzzy igualou os melhores resultados no caso foi de 2,85% com o método de rede neural de aplicação.

Desta forma, obtivemos uma Taxa de Erro Real (8,36%) onde o melhor caso foi (16,99%) com a rede neural da aplicação.

A aplicação da Lógica Fuzzy foi comparada com os métodos de reconhecimento e classificação de padrões aplicados separadamente em bancos de dados e, assim, pode-se comprovar sua eficácia.

A partir da Tabela VI, pode-se observar que o sistema de lógica fuzzy pode sintetizar e integrar o desempenho das três técnicas de reconhecimento e classificação de padrões testados, obtendo uma melhor classificação.

Assim, o sistema de decisão fuzzy projetado pode inferir uma classificação aproveitando os pontos fortes individuais de cada técnica para suprir as deficiências específicas em alguns erros de classificação obtidos por uma determinada técnica.

#### **4 CONCLUSÃO**

A metodologia visa criar um sistema fuzzy que pode gerenciar, sintetizar e integrar diferentes métodos de reconhecimento e classificação de padrões, melhorando assim o desempenho geral do sistema.

O sistema Fuzzy aplicado não só apresentou melhor desempenho geral como apresentou melhores resultados na redução do erro II, e no caso do erro I igualou o melhor resultado.

O modelo Mamdani foi criado para considerar a taxa de erro real para a classificação de uma nova observação, obtendo assim um resultado final que inclui as principais vantagens de cada método Reconhecimento e Classificação de Padrões, atendendo assim às fragilidades específicas de cada método.

A aplicação da Lógica Fuzzy foi comparada com os métodos de Reconhecimento e Classificação de Padrões aplicados separadamente nas bases de dados podendo assim comprovar sua eficácia.

Por fim, podemos dizer que o modelo Mamdani foi capaz de sintetizar os resultados dos modelos de Classificação de Padrões de Reconhecimento, eliminando a necessidade de cada método, tendo assim um melhor desempenho geral.

**REFERÊNCIAS**

S. M. Amin, and B. F. Wollenberg, "Toward a Smart Grid," *IEEE Power & Energy Magazine*, pp. 34–41, Sep.-Oct. 2005.

P. Zhang, F. Li, and N. Bhatt, "Next-Generation Monitoring, Analysis, and Control for the Future Smart Control Center," *IEEE Trans. on Smart Grids*, vol. 1, no. 2, pp. 186–192, Sep. 2010.

G. T. Heydt, "The Next Generation of Power Distribution Systems," *IEEE Trans. on Smart Grids*, vol. 1, no. 3, pp. 225–235, Dec. 2010.

L. A. Zadeh, Fuzzy Sets. *Information and Control*, Vol. 8, 1965. p. 338-353.

R. A. Johnson and D. W. Wichern. *Applied Multivariate Statistical Analysis*. 4th ed. New Jersey: Prentice-Hall, inc., 1998.

S. O. Haykin, *Neural Networks: A Comprehensive Foundation*. Prentice Hall; 2nd edition. 1998.  
ANEEL. *Resolução N° 505, de 26 de novembro de 2001*, available at <http://www.aneel.gov.br>.

ONS (Power System National Operator). *Procedimentos de Rede, Submódulo 2.2, Padrões de Desempenho da Rede Básica*, available at <http://www.ons.org.br>.

W.E. Souza; A.R. Aoki, A. Chaves-Neto, R. A. Peniche, M. R. Ortega. Voltage Total Harmonic Distortion Analysis through Transformer s Characteristics and Energy Use Data. In: International Conference on Power Systems Transients, 2009, Kyoto. Proceedings of IPST 2009.

Lachenbruch, P. A. *Discriminant Analysis*. New York, Halfner: 1975.