


em SEE são classificados em:

A. Perda de Geração (PG)

O desequilíbrio entre a geração e a carga de um SEE resulta em afundamento na frequência. Na Figura 2 é apresentado um registro real de uma perda de geração no SIN.


Figura 2 – PG na região Norte do SIN



B. Rejeição de Carga (RC)

Quando ocorre a atuação de um sistema de proteção que leva a abertura de um disjuntor associado a uma carga importante do sistema, ocorre desequilíbrio de carga/geração, mas nesse caso a frequência do sistema irá aumentar devido a aceleração dos geradores. O que também ocorre quando há um desligamento de conversora que fornece potência a SEE vizinhos, mas desacoplados em frequência. Na Figura 3 é apresentado um registro de uma rejeição de carga no SIN.


Figura 3 – RC de 630MW - Bloqueio da Conversora Garabi 2 no RS



C. Desligamento de Linha de Transmissão (DLT)

A ocorrência de eventos de DLT em SEE malhados altera os fluxos das linhas remanescentes, com a ocorrência de uma sequente oscilação em torno da frequência nominal, principalmente quando se trata de DLTs de alta tensão ($\geq 500\text{kV}$) com fluxo significativo. Essas características são mais visíveis nas PMUs mais próximas do evento, o que caracteriza um evento do tipo local, como ilustrado na Figura 4.

Figura 4 – DLT 500kV Serra Mesa 2/Luziânia C-1, Brasília – 10s



D. Oscilações (OS)


Perda de geração, faltas, rejeição de carga e problemas em controladores produzem oscilações eletromecânicas devido à redistribuição das potências entre os geradores. Contudo,

existem oscilações que não possuem um evento claro que as originou. Se estas oscilações não forem amortecidas, podem provocar ilhamentos, desligamentos de componentes ou blecautes devido às atuações das proteções do sistema.

O desligamento de um elo DC de corrente contínua traz oscilações de grande amplitude quando de sua desconexão por falha. No SIN, o Elo 600kV Madeira traz a geração dos complexos hidrelétricos Santo Antônio e Jirau ($\approx 6000\text{MW}$), localizados no Rio Madeira, região Norte, para a região Sudeste. Também existe um transformador provisório e um conversor back-to-back, instalados na SE Coletora Porto Velho 500kV, em Rondônia, para atender a carga do subsistema Acre-Rondônia [8].

As PMUs UFAC e UNIR estão instaladas nas capitais dos estados de Acre e Rondônia. Estas PMUs têm registrado fortes oscilações eletromecânicas quando ocorrem bloqueios ou perdas de geração transportadas pelo Elo DC, conforme ilustrado na Figura 5.

Figura 5 – Perda de 550MW na UHE Santo Antonio e 85MW na UHE Jirau fornecidos ao Elo DC Madeira 600 kV (RO-SP)



III. DETECTOR E CLASSIFICADOR DE EVENTOS EXISTENTES

Detectar um evento representa capturar a repercussão dos eventos nas grandezas elétricas, isto é capturar o momento em que o evento atinge cada PMU. Previamente às técnicas de detecção, existe uma primeira etapa de pré-processamento do sinal mediante a filtragem. Em [3] foram implementados o Filtro de Média Móvel Passa Faixa, o Filtro de Média Móvel com Taxa de Variação e o Filtro de Kalman, destacando-se os dois últimos em uma série de análise de eventos.

Após o pré-processamento do sinal, realiza-se a detecção do evento onde uma técnica é utilizando um limiar estático, na qual a detecção do evento é realizada mediante a ultrapassagem de um limiar preestabelecido, visando capturar o instante exato que o evento atinge as PMUs. Esta metodologia foi abordada em [3] considerando um limiar fixo.


Contudo, não é possível trabalhar sempre com um limiar de detecção fixo porque dois eventos reais nunca são iguais, podendo variar de acordo a magnitude da carga interrompida.

O sucesso desta técnica depende do comportamento do evento na frequência. As principais dificuldades ocorrem quando a frequência pré-evento tem um comportamento não constante, o que provoca a detecção de falsos eventos.

O número de falsas sinalizações pode aumentar drasticamente com a escolha de um limiar de detecção menor ao preestabelecido, estas falsas sinalizações correspondem a transitórios e regiões de operação normal do SEE. Este problema inviabiliza a implementação em tempo real da técnica de detecção mediante limiar estático.

Classificar eventos é organizá-los a partir de suas características particulares de forma automática. Os métodos de classificação se dividem em dois tipos: determinísticos e estatísticos. Na Figura 6 estão esquematizados os passos típicos de um sistema de classificação.

Figura 6 – Tipos de sistemas de classificação de eventos



O classificador de eventos existente no projeto MedFasee é baseado em um conjunto de regras implementadas utilizando lógica condicional [1]. Este tipo de classificador é similar a um sistema especialista sem memória de trabalho. Os classificadores baseados em sistemas especialistas são amplamente utilizados na literatura tradicional [7].

Este classificador extrai informações das características dinâmicas dos eventos para sua classificação de modo empírico (a partir da experimentação de diversos casos reais). Para isto são sintonizados limiares que avaliam tanto a amplitude do evento como sua duração no tempo e que precisam ser ajustados previamente. Os eventos são classificados em:

- **Saltos**, característicos de curtos-circuitos e chaveamentos.
- **Desvio de frequência**, característicos de perda de geração e rejeição de carga.

O classificador de eventos existente tem bom funcionamento na análise de eventos sistêmicos. Entretanto, ele apresenta dificuldades nas seguintes situações:

- na identificação de saltos (característico de DLTs), o classificador apresenta dificuldade uma vez que na etapa de filtragem, os saltos e ruídos são atenuados.
- na identificação de oscilações, o classificador os mal caracteriza como eventos do tipo perda de geração ou rejeição de carga em função da direção da primeira crista oscilatória.

Recentemente, classificadores de eventos, baseados em RNAs, com arquitetura *Perceptron* de múltiplas camadas, têm sido desenvolvidos. Em [4] foram simulados 200 casos para cada tipo de evento, a partir da construção de modelos matemáticos de eventos, logo foi utilizado o toolbox de redes neurais do Matlab para treinamento, validação e teste. Contudo, os resultados da aplicação desta metodologia não foram explicados em detalhes na referência.

[6] em sua tese de doutorado, realizou uma investigação utilizando sinais reais da frequência elétrica e propôs um classificador neural de eventos com uma eficiência de 97,7% na identificação de PG, RC e DLT na interligação leste, utilizando o toolbox de redes neurais do Matlab. Esta proposta vem sendo utilizada em razão de sua característica de trabalhar bem em tempo real, com potencial de reconhecer eventos

automaticamente após 2 segundos de ocorrido [9].


A proposta do presente trabalho é projetar, implementar, treinar e utilizar um classificador baseado em redes neurais, a partir dos dados históricos de eventos do projeto MedFasee. Ressalta-se que uma das sugestões de trabalhos futuros em [3] foi desenvolver um identificador de eventos que utilize técnicas de inteligência artificial.

IV. CLASSIFICADOR NEURAL PROPOSTO PARA O SIN

A utilização de redes neurais artificiais (RNAs) para a classificação de eventos a partir de dados da frequência torna-se justificável, pelos motivos seguintes [10]: sua habilidade em classificar padrões, sua habilidade de generalização; sua tolerância a falhas; sua facilidade de prototipagem e sua eficiência para tratar diversos problemas não-lineares.

O treinamento exitoso de uma RNA depende da qualidade e da quantidade de casos de eventos históricos previamente classificados. Neste contexto o projeto MedFasee tem uma base de dados histórico online desde julho de 2010. Esses dados podem ser extraídos a partir do software MedPlot [11], uma vez conhecendo-se o horário do evento. A seguir são descritos os passos do projeto conforme a Figura 7. Os valores percentuais indicados representam uma ponderação para ressaltar o nível de dificuldade de cada passo, ressaltando os passos 2 e 3.

Figura 7 – Projeto do Classificador Neural de Eventos




A. Projetar o Sistema

Significa definir as entradas e as saídas da RNA. As entradas referem-se à quantidade de características a serem inseridas na rede neural. Neste trabalho é utilizado uma janela de dados de 20 segundos com 1 segundo pré-evento e aproveitando a taxa de amostragem de 60 fasores por segundo. Isto é, 1200 dados de entrada ($x_1, x_2, \dots, x_{1200}$) inicialmente.

As saídas referem-se ao número de classes na qual serão organizados os eventos quando forem apresentados à rede neural. Neste trabalho são definidos 4 tipos de classes de eventos: PG, RC, DLT e OS. Na Figura 8 é mostrado em conjunto a forma geral do projeto do sistema.

Figura 8 – Projetar o sistema: entradas e saídas



B. Selecionar casos reais de Eventos do SIN

Foi dedicado um longo tempo para a organização de uma base de dados de eventos ocorridos no SIN, e armazenamento

automático devido à falta de um algoritmo automático de detecção de eventos. Isto tornou este passo exaustivo e não trivial. Assim, todos os eventos considerados neste trabalho correspondem àqueles informados pelo ONS no seu informativo preliminar diário da operação (IPDO e pelo Informativo Diário do Desempenho do SMSF (IDDS) do projeto MedFasee BT.

Foi criada uma base de dados de Eventos em Excel onde estão organizados todos os eventos reais ocorridos no SIN, entre julho de 2010 e julho de 2015. Cada evento contém informações relativas a hora exata, o desvio na frequência, a potência interrompida, o local do evento e outras observações relevantes. As Tabelas 1 – 3, são respectivamente, extratos das tabelas completas relativas a PG, RC e DLT apresentadas em [12].

Tabela 1 – Extrato da listagem de Eventos PG no SIN

N	Data	Horario UTC	Tipo	Busca (s)	T _{detecção} (s)	Δf (Hz)	ΔP Inf (MW)	Local Informado	
25	20140511	13:53:15.6	PG	60	14.7	0.27	NãoInf	Região Sul	7 PMUs do MedFasee.
26	20140523	18:38:43.7	PG	60	12.7	0.15	722	Região Nordeste	19 PMUs do MedFasee.
27	20140528	07:31:49	PG	60	10	0.25	NãoInf	Não informado	18 PMUs do MedFasee.
28	20140607	17:12:9.7	PG	600	66	0.31	2800	Paraná - São Paulo	21 PMUs do MedFasee.
29	20140612	06:46:48.5	PG	60	9.5	0.25	NãoInf	São Paulo	21 PMUs do MedFasee.
30	20140613	14:27:26	PG	60	10.9	0.19	NãoInf	Elo DC Madeira	19 PMUs do MedFasee.

Tabela 2 – Extrato da listagem de Eventos RC no SIN

Data (UTC)	Horario (UTC)	Tipo	Busca (s)	T _{detecção} na Consulta	Δf (Hz)	ΔP Inf (MW)	Local Informado	OBSERV
20120229	18:48:29.1	PC	180	88	0.28	896	MA	13 PMUs do MedFasee inclui Nord
20120509	16:32:58.8	PC	120	57.7	0.12	400	PA	12 PMUs do MedFasee. UnB com c
20120611	22:50:43.2	PC	180	42.2	0.11	437	RJ	12 PMUs do MedFasee.
20121010	11:27:52	PC	120	51	0.26	984	RS	14 PMUs do MedFasee.
20121023	13:28:39.9	PC	180	95	0.13	480	SP	16 PMUs (MedFasee BT + MedFasee

Um benefício desta base de dados é que permite conhecer a quantidade total de casos existentes para cada tipo de evento permitindo avaliar a existência ou não de casos reais suficientes para se treinar uma RNA.

Tabela 3 – Extrato da listagem de Eventos DLT no SIN

Data	Horario (UTC)	Tipo	Estado Informado	Local Informado	PMUs sensibilizadas	F1_max	F2_Max	Desvio frequência	OBSERV
20140225	21:40:29.3	DLT	GO	LT 500kV Serra Mesa2/ Luziania C-1	UNIB	59.73	60.38	0.65	Provoca posterior oscilaç
					UFMT	60.14	59.62	0.52	Interessa também o mód
					UFMG	59.86	60.09	0.23	
20140313	15:55:34.3	DLT	CE	LT 500kV Pecemil/ Fortaleza1	UFCE	59.22	60.36	1.14	
					UFMA	59.85	60.11	0.26	
					PTI	60.34	59.64	-0.7	
20140605	20:02:39	DLT	PR	LT 765kV Foz-vaiporã C1	UNIFEI	59.95	60.1	0.15	
					UTPR	59.95	60.1	0.15	
					PTI	59.97	60.26	0.29	
20140605	20:03:14.7	DLT	PR	LT 765kV Foz-vaiporã C2	UNIFEI	59.97	60.03	0.06	Oscilação dos Modos N:
					UTPR	59.97	60.03	0.06	
					PTI	60.23	59.81	-0.42	
20140924	09:37:51.8	DLT	PR	LT 765kV Foz-vaiporã C3	UTPR	59.92	60.11	0.19	
					UNIFEI	59.97	60.09	0.12	

C. Extrair (simular) seus dados

A partir do conhecimento de um evento, as informações das PMUs armazenadas no PDC são extraídas mediante o aplicativo MedPlot [11], criando uma pasta que contém as informações de cada PMU em formato ASCII. Esses arquivos são previamente processados usando uma ferramenta desenvolvida que descarta as informações não utilizadas e salva os dados e o gráfico da frequência elétrica durante cada evento, que é útil para visualização no treinamento da RNA.

Cada arquivo é armazenado em uma pasta que indica o tipo de evento que ele representa. Esta organização é útil porque facilita o processo de treinamento das RNAs estudadas. O período de tempo dos dados extraídos para cada tipo de evento é de 20 segundos, contudo eventos como DLT e OS apresentam oscilações que são amortecidas em 7-9 segundos. A frequência extraída possui 1 segundo de dados de frequência pré-evento seguido dos 19 segundos posteriores do evento. Isto para que a RNA aprenda a diferenciar o comportamento da frequência pré-evento, durante o evento e após o evento.

Durante a extração de dados, foram excluídos registros de PMUs que perderam a comunicação com o PDC durante o evento (muitas vezes próximas ao local do evento), isto porque não oferecem informações úteis para o treinamento da RNA.

D. Executar pré-processamento dos dados

A etapa de pré-processamento tem como objetivo estudar a redução do número de entradas da RNA. As RNAs precisam que os dados de entrada sejam normalizados previamente. Destaca-se que arquiteturas híbridas, associando técnicas de processamento de sinais e RNAs estão em destaque recentemente [10].

Uma ferramenta foi implementada em Matlab para a leitura dos arquivos excel resultado do passo anterior, e posterior criação das matrizes de cada tipo de evento. O vetor coluna de cada matriz representa uma amostra de treinamento com 1200 dados cada um.

A arquitetura de RNA utilizada é do tipo *feedforward Perceptron* de múltiplas camadas (PMC). O algoritmo de aprendizado utilizado em seu treinamento é o *Error-Backpropagation*.

A execução da etapa de treinamento requer duas matrizes: A matriz Treinamento_Entrada (*training_input*) é de ordem $m \times n$, onde m é o número de dados que contém a amostra e n é o total de amostras a serem utilizadas. A matriz Treinamento_Saida (*training_output*) é de ordem $k \times n$, onde k é o número de classes e n é novamente o total de amostras de treinamento. A Tabela 4 e a Tabela 5 mostram a estrutura de ambas as matrizes, para fácil ilustração foram consideradas 20 dados de entrada ao invés dos 1200 dados.

Tabela 4 – Organização da Matriz de Treinamento-Entrada

Entradas (Segundos)	PG	RC	DLT	OS
1	60,00	60,00	60,00	60,00
2	59,98	60,02	60,30	60,60
3	59,97	60,03	59,70	59,40
5	59,86	60,14	60,15	60,30
7	59,75	60,25	59,85	59,70
8	59,78	60,22	60,00	59,80
13	59,86	60,14	60,00	59,85
18	59,94	60,06	60,00	59,87
19	59,95	60,05	60,00	59,88
20	59,95	60,05	60,00	59,90

Tabela 5 – Organização da Matriz de Treinamento-Saída

Saídas	PG	RC	DLT	OS
PG	1	0	0	0
RC	0	1	0	0
DLT	0	0	1	0
OS	0	0	0	1

E. Seleção das amostras para o Treinamento

Um tempo significativo foi dedicado à seleção apropriada dos casos de treinamento. A ideia era pegar aqueles eventos que repercutiram no comportamento do evento no sinal da frequência, a qual possui variações lentas próprias dos contínuos desbalanços de geração-carga do sistema.

Foi assim que se utilizaram amostras de PG com desvio da frequência maior que 0,08Hz (aprox. 530MW), amostras de RC com desvio de frequência maior que 0,07Hz (aprox. 440MW). Nas amostras de DLT, foram selecionados registros de PMUs próximas ao evento, porque mostram o salto inicial na frequência seguido de uma oscilação devido à redistribuição do fluxo de potência nas linhas remanescentes.

No caso das amostras de OS foram selecionados registros de fortes oscilações interárea, visíveis nas PMUs UFAC e UNIR, devido à repercussão do desligamento do Elo DC Madeira na

região Acre – Rondônia. Já os registros das outras PMUs do SIN foram usados nos conjuntos das amostras PG, porque o desligamento do Elo DC acarreta a perda de geração do complexo hidrelétrico do Madeira (UHEs Jirau e Santo Antonio) para o sistema.

Dada a natureza sistêmica dos eventos PG e RC e a natureza local dos eventos DLT e OS, é esperado que se tenha um número maior de amostras de eventos sistêmicos. Os casos que não apresentaram um comportamento similar ao tipo de evento ao qual correspondiam, foram excluídas do conjunto de treinamento.

F. Configuração topológica da rede PMC

A rede PMC proposta é constituída pela camada de entrada, a camada neural escondida e a camada neural de saída.

Na camada de entrada, inicialmente são mostrados 1200 dados que correspondem a varredura de 20 segundos à taxa de 60 fasores por segundo, constituído por 1 segundo pré-evento e 19 segundos após o evento. O tempo de treinamento das RNAs é proporcional a quantidades de dados de entrada desta, isto motiva a estudar o máximo fator de dizimação dos dados de entrada e o mínimo tamanho da janela de dados de entradas.

Na camada neural escondida é importante estudar o número de neurônios que irá possuir (n_1). Isso é determinado mediante tentativa/erro observando o desempenho global da rede PMC. Neste trabalho, foi considerado 20 neurônios conforme pesquisa similar [6].

Na camada neural de saída, várias redes neurais foram criadas. Uma com as quatro saídas (PG, RC, DLT e OS), outra com três saídas (PG, RC e DLT), outras duas redes PMC com duas saídas (PG e RC) (DLT e OS) e, finalmente, redes especializadas para cada saída. O critério de seleção da melhor arquitetura a usar na operação da rede PMC é a partir do valor do seu desempenho global.

Os outros parâmetros internos da rede PMC: pesos sinápticos e bias iniciais; função de ativação na camada neural escondida; função de ativação na camada neural de saída; taxa de aprendizado e tipo de treinamento (algoritmo do gradiente conjugado escalar – *trainscg*) foram utilizados os valores padrão da *ANN toolbox* do Matlab [13].

G. Treinamento, Validação e Teste

Uma vez que as matrizes Treinamento-Entrada e Treinamento-Saída foram criadas, o treinamento utilizando a *ANN Toolbox* (Pacote Artificial Neural Network) do Matlab é bastante simples. O toolbox requer o número de neurônios na camada neural escondida e a separação dos casos a serem usados nos grupos de treinamento, validação e teste. Validação, refere-se a medida do grau de generalização da rede PMC. Se, durante o treinamento, a capacidade de generalização da rede começa a piorar, o processo de treinamento é abortado para evitar a sobre especialização da rede PMC [10].

Um algoritmo foi codificado em Matlab para criar, treinar e testar as diferentes redes PMC implementadas no passo anterior, utilizando a *ANN Toolbox*.

classificador neural proposto foi possível utilizando o *ANN Toolbox* do Matlab. O problema aqui tratado é de reconhecer o tipo do evento a partir do reconhecimento do padrão característico do evento na frequência elétrica, sendo usado uma arquitetura Perceptron de múltiplas camadas (PMC).

A camada de entrada está conformada por 1200 entradas. A camada neural escondida está conformada por 20 neurônios. A camada neural de saída está conformada, neste caso particular, por 2 neurônios, já que esta rede PMC foi treinada para reconhecer unicamente eventos tipo PG e RC. O número de neurônios da camada neural de saída poderá mudar de 1 a 4, quando forem tratados todos os tipos de eventos.

Esta análise visa vislumbrar a qualidade do classificador de eventos proposto. É importante salientar que o trabalho se encontra em fase de andamento, onde resultados parciais já foram obtidos. Estes resultados são mostrados na subseção seguinte.

A. Resultados prévio ao treinamento

O conjunto de eventos utilizados durante o treinamento da rede neural com arquitetura *feed forward* PMC, foram extraídos dos servidores do SMSF MedFasee selecionando eventos reais no SIN, que ocorreram no período 03/2010 – 07/2015. A maioria destes eventos foram confirmados com os agentes do SIN. A lista de todos os eventos detectados e extraídos mediante as ferramentas computacionais desenvolvidas neste trabalho são mostrados na Tabela 6.

Tabela 6 – Separação dos casos extraídos do SIN para cada evento

Tipo de Evento	Abrev.	# Eventos	# Casos de Treinamento
Perda de Geração	PG	55	876
Rejeição de Carga	RC	29	421
Desligamento de Linha de Transmissão	DLT	17	46
Bloqueio do Elo 600kV DC Madeira	OS	7	14
Total de Eventos e Registros para treinar a rede:		108	1357

O conjunto de casos de treinamento é constituído pelos registros de todas as PMUs que detectaram o evento. O total de casos extraídos são 1357, distribuídos: PG (65%), RC (31%), DLT (3%) e OS (1%). O elevado número de casos PG/RC é devido a sua natureza sistêmica, sendo detectado em média por 16 PMUs. O reduzido número de casos DLT/OS é devido que seu efeito na frequência é visualizado próximo ao local do evento, sendo detectado em média por 3 PMUs.

Foram gerados gráficos de todos os casos de treinamento para cada tipo de evento. Cada caso de treinamento tem amplitude diferente e correspondem a registros reais de eventos no SIN Brasil. Os 876 casos PG são mostrados na Figura 9 e obedecem a eventos reais com perda de geração intempestiva $\geq 450\text{MW}$. A maioria deles confirmado mediante comunicação direta com o ONS. Os 421 casos RC são mostrados na Figura 10 e obedecem a eventos reais, informados no IPDO do ONS, com rejeição de carga $\geq 300\text{MW}$.

V. RESULTADOS

O ambiente de treinamento, validação e teste do

Figura 9 – PG de casos reais do SIN extraídos





Figura 10 – RC de casos reais do SIN extraídos



Os 46 casos DLT mostrados na Figura 11 e obedecem a eventos informados no IPDO, de linhas de transmissão com nível de tensão $\geq 500\text{kV}$. O 47% dos casos correspondem à linha 765kV da UHE Itaipu. Os 14 casos OS são mostrados na Figura 12 e correspondem a eventos de oscilações interárea no subsistema Acre/Rondônia, causadas pelo bloqueio do Elo 600kV Madeira. Alguns informados no IPDO e outros confirmados via comunicação direta com o ONS.

Figura 11 – DLT de casos reais do SIN extraídos





Figura 12 – OS de casos reais do SIN extraídos




B. Teste utilizando a ANN Toolbox

Neste trabalho foi usado uma única camada neural escondida com 20 neurônios. O total de casos extraídos foi dividido em 3 conjuntos todos diferentes entre si: treinamento (70%), validação (15%) e teste (15%). Esta divisão dos dados é bastante empregada no treinamento de redes PMC, com o objetivo de dar uma maior percentagem de casos para o treinamento da rede e assim ela possa extrair as características internas destes casos.

Os valores dos outros parâmetros internos como pesos sinápticos, tipo de função de ativação e algoritmo de treinamento são os configurados por default na ANN toolbox. Foi utilizada a função *patternnet* (*pattern recognition network*) do Matlab, para classificar eventos do tipo PG e RC. Ela utiliza como função de ativação default, a tangente hiperbólica tanto na camada neural escondida como na camada neural de saída.

Durante o processo de treinamento, a ANN Toolbox apresenta a época, o tempo de execução, o valor do desempenho e do gradiente a cada iteração. A rede PMC treinada convergiu em 32 épocas, a curva de aprendizagem atualizada a cada época é mostrada na Figura 13.

Figura 13 – Treinamento do PMC: Erro quad. médio vs. # épocas



A avaliação do classificador é feita por meio da comparação entre o resultado obtido na classificação e a indicação real do tipo de evento ao qual corresponde. Esta Tabela 7 é conhecida como matriz de confusão.

Tabela 7 –Matriz de confusão para avaliação de eventos PG e RC

Training Confusion Matrix			Validation Confusion Matrix		
Output Class	1	2	Output Class	1	2
	602 66.4%	0 0.0%		135 69.2%	0 0.0%
	0 0.0%	305 33.6%		0 0.0%	60 30.8%
Output Class	1	2	Output Class	1	2
	100% 0.0%	100% 0.0%		100% 0.0%	100% 0.0%
	100% 0.0%	100% 0.0%		100% 0.0%	100% 0.0%

Test Confusion Matrix			All Confusion Matrix		
Output Class	1	2	Output Class	1	2
	139 71.3%	0 0.0%		876 67.5%	0 0.0%
	0 0.0%	56 28.7%		0 0.0%	421 32.5%
Output Class	1	2	Output Class	1	2
	100% 0.0%	100% 0.0%		100% 0.0%	100% 0.0%
	100% 0.0%	100% 0.0%		100% 0.0%	100% 0.0%

O resultado mostrado na Tabela 7 indica que o classificador PG/RC consegue efetivamente diferenciar entre PG e RC em 100% dos casos de treinamento, validação e teste.

VI. CONCLUSÕES

Este artigo apresenta resultados de um classificador neural na classificação de eventos no SIN usando sincrofasores. Um conjunto de casos de treinamento para classificar eventos sistêmicos e locais no SIN foram extraídos, etiquetados e armazenados em uma matriz. Também foi desenvolvido um algoritmo de treinamento de redes PMC, porém ainda precisa ser adaptada para este problema real. Um teste envolvendo eventos sistêmicos foi implementado utilizando ANN Toolbox. A rede convergiu em apenas 32 épocas, diferenciando satisfatoriamente todos os casos utilizados.

O projeto de implementação deste classificador de eventos, exigiu a criação de uma base de dados de eventos no SIN, muitos destes eventos foram confirmados com os agentes do setor elétrico. Esta base de dados pode ser utilizada para o estudo de outras aplicações.

Por fim, quer se destacar que a utilização SMSF já se encontra em uma etapa de maturidade depois dos grandes avanços na monitoração em tempo real dos SEE, voltando-se agora no desenvolvimento de aplicações, como a classificação de eventos em tempo real, que permitirá melhorar a consciência situacional sob perturbações dos operadores de tempo real.

VII. REFERÊNCIAS

- [1] ZIMMER, V.; Vieira, P.C.C.; Zarzosa, M.A.D.; Agostini, M.N. e Decker, I.C. *Aplicativo Computacional para a Caracterização de Eventos em Sistemas Elétricos usando Sincrofasores*. XXIII-SNPTEE. Foz de Iguaçu – PR, 2015.
- [2] BYKHOVSHKY A. e CHOW J.H. “Power system disturbance identification from recorded dynamic data from Northfield Substation” Int. J. Elect. Power Energy Syst, vol. 25, no. 10, pp. 787-795, Dec 2003.
- [3] ZIMMER, V. Detecção, Identificação e Localização de Eventos usando Sincrofasores. (Mestrado) – UFSC, Florianópolis, SC, julho 2013.
- [4] ZHENG, G, *Classification of Power system disturbances based on wide-area frequency measurements* in Innovative Smart Grid Technologies (ISGT), 2011 IEEE PES, pp. 1-4, 17-19 January, 2011a.
- [5] ZHENG, G and CRAVEN, R, *Multiclass Support Vector Machines for Power system disturbances classification based on wide-area frequency measurements* in Southestcon, 2011 Proceedings of IEEE, pp. 68-72, March, 2011b.

- [6] MARKHAM P. Data Mining and Machine Learning Applications of Wide-Area Measurement Data in Electric Power Systems. December 2012. (Doctoral Dissertation). The University of Tennessee, Knoxville.
- [7] BOLLEN, M.H.J.; Gu, I.Y.H. *Signal Processing of Power Quality Disturbances*. IEEE Press Series on Power Engineering, Mohamed E. El-Hawary, Series Editor. Piscataway, NY, USA, 2006
- [8] DE OLIVEIRA, D.B.; ALVES, T.M.T.S.; NOHARA, A.A.; QUINTÃO, P.E.M. e SARDINHA, S.L.A. *Análise de Perturbação envolvendo o Sistema Madeira com Reflexos para a área Acre e Rondônia*. XXIII SNPTEE. Foz de Iguaçu – PR, outubro 2015.
- [9] LIU, Y.; ZHAN, L.; ZHANG, Y.; MARKHAM, P.N.; ZHOU, D.; GUO, J.; LEI, Y.; KOU, G.; YAO, W.; CHAI, J.; and LIU, Y. *Wide-Area Measurement System Development at the Distribution Level: an FNET/GridEye Example* in IEEE Transactions on Power Delivery, volume PP Issue 99, Date of Publication: March 16 2015, pp. 1-11.
- [10] SILVA, I.N.; SPATTI H. e FLAUZINO R. A. *Redes Neurais Artificiais para engenharia e ciências aplicadas*. ArtLiber Editora Ltda, 2010.
- [11] LEANDRO, R.B.; Zimmer, V.; Jeremias, T. Decker, I.C. *Ambiente Computacional de Análise do Desempenho Dinâmico de Sistemas Elétricos utilizando Sincrofasores*. XXII SNPTEE. Brasília – DF, 2013.
- [12] ZARZOSA, M.A.D. *Análise de Eventos em Sistemas de Energia elétrica usando Sincrofasores*. (Mestrado) – UFSC, Florianópolis, SC, 2016.
- [13] MATLAB R2011a Help, Mathworks, Natick, MA, 2011.