TESE
1178

Universidade Federal de Itajubá
Programa de Pós-Graduação em Engenharia Elétrica

Classificação de Descargas Parciais em Equipamentos Isolados a SF_6 a Partir de Monitoramento On-Line por UHF

José Guilherme Rodrigues Filho

Itajubá

2002



UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

CLASSIFICAÇÃO DE DESCARGAS PARCIAIS EM EQUIPAMENTOS ISOLADOS A SF_6 A PARTIR DE MONITORAMENTO ON-LINE POR UHF

Dissertação apresentada à Universidade Federal de Itajubá para obtenção do título de Mestre em Engenharia Elétrica

UNIVERSIDADE FEDERAL DE ITAJUBA
Bibliote
MAT
BIN
UNIFEI

JOSÉ GUILHERME RODRIGUES FILHO

ITAJUBÁ

2002

CLASS. 537.52(043.2)
CUTTER. A696c
TOMBO. 1178

Ministério da Educação
UNIVERSIDADE FEDERAL DE ITAJUBÁ
Criada pela Lei 10.435, de 24 de abril de 2002

ANEXO I

PRONUNCIAMENTO DA BANCA EXAMINADORA

A Banca Examinadora, abaixo assinada, nomeada pela Portaria nº 174, de 21 de junho de 2002, considerando o resultado do Julgamento da Prova de Defesa Pública da Dissertação de Mestrado intitulada **"Classificação de Descargas Parciais em Equipamentos Isolados a SF_6 a Partir de Monitoramento On-line por UHF"** apresenta pronunciamento no sentido de que o Coordenador dos Cursos de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Itajubá solicite ao DRA (Departamento de Registro Acadêmico) a expedição do título de **Mestre em Ciências em Engenharia Elétrica**, na **Área de Concentração Sistemas Elétricos de Potência**, satisfeitas as demais exigências regimentais, a **José Guilherme Rodrigues Filho.**

Itajubá, 21 de Junho de 2002.

Profª. Marley Maria Bernardes Rebuzzi Vellasco
1ª Examinadora - PUC-Rio

Prof. Cláudio Ferreira
2º Examinador – UNIFEI

Prof. Manuel Luis Barreira Martinez
3º Examinador – UNIFEI

Prof. Alexandre Pinto Alves da Silva
4º Examinador - UNIFEI

Ministério da Educação
UNIVERSIDADE FEDERALDE ITAJUBÁ
Criada pela Lei 10435, de 24 de abril de 2002

ANEXO II

FOLHA DE JULGAMENTO DA BANCA EXAMINADORA

Título da Dissertação: **"Classificação de Descargas Parciais em Equipamentos Isolados a SF_6 a Partir de Monitoramento On-line por UHF"**

Autor: **José Guilherme Rodrigues Filho**

JULGAMENTO

Examinadores	Conceito	Rubrica
1º	A	
2º	A	
3º	A	
4º	A	

Resultado Médio: Conceito: A, ou seja, aprovado

Observações: _____

Itajubá, 21 de Junho de 2002

Marley Maria Bernardes Rebuzzi Vellasco
1º Examinador – PUC-Rio

Cláudio Ferreira
2º Examinador - UNIFEI

Manuel Luis Barreira Martinez
3º Examinador - UNIFEI

Alexandre Pinto Alves da Silva
4º Examinador - Orientador

JOSÉ GUILHERME RODRIGUES FILHO

CLASSIFICAÇÃO DE DESCARGAS PARCIAIS EM EQUIPAMENTOS ISOLADOS A SF_6 A PARTIR DE MONITORAMENTO ON-LINE POR UHF

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Itajubá como requisito para obtenção do título de Mestre em Engenharia Elétrica

Área de concentração:
Sistema de Potência

Orientador:
Prof. Dr. Alexandre P. Alves da Silva

Co-orientador:
Prof. Dr. Manuel L. Barreira Martinez

ITAJUBÁ

JUNHO/2002

À minha esposa, Maria Luiza

pelo apoio constante.

Aos meus filhos Ana Luiza e Luiz Guilherme

pela compreensão dos momentos em

que me fiz ausente.

AGRADECIMENTOS

À Universidade Federal de Itajubá.

À Itaipu Binacional.

Aos Profs. Drs. Alexandre P. Alves da Silva e Manuel L. Barreira Martinez

pela orientação, dedicação e apoio.

Ao companheiro e colega de estudos Jaime Suñé.

Aos colegas e funcionários do GESIS/IEE/PPG, especialmente Cristina Silva.

A todos que direta ou indiretamente contribuíram

para a realização desta pesquisa.

A Deus, o grande arquiteto do Universo que

nos ilumina e protege.

“defrontamo-nos então com o trabalho

de adaptar nossa técnica

às novas condições ”

Sigmund Freud, 1919

ÍNDICE

LISTA DE FIGURAS vi
LISTA DE TABELAS ix
RESUMO x
ABSTRACT xi
1 - INTRODUÇÃO 1
1.1 - Evolução da técnica de medição de DP 2
1.2 - Medição de DP em equipamentos isolados a SF_6 9
1.3 - Definição do problema 14
2 - ESCOLHA DAS TÉCNICAS PARA APLICAÇÃO 16
2.1 - Objetivo do sistema 18
2.2 - Características do ambiente 20
2.3 - Técnicas mais adequadas para assimilação do conhecimento 22
3 - APLICAÇÃO DAS TÉCNICAS SELECIONADAS 25
3.1 - Redes Neurais utilizando operadores estatísticos no formato PRPD (Phase Resolved Partial Discharge) 25
3.2 - Redes Neurais utilizando operadores estatísticos no formato PRPS (Phase Resolved Pulse Sequence) 31
3.3 - Redes Neurais utilizando a grade de pixels do gráfico 3D φxqxN 33
4 - RESULTADOS 35
4.1 - Redes Neurais utilizando operadores estatísticos no formato PRPD (Phase Resolved Partial Discharge) 38
4.1.1 - Refinamento dos operadores Sk e Ku 43
4.1.2 - Histograma das distribuições Hn(φ) e Hqn(φ) 45
4.2 - Redes Neurais utilizando operadores estatísticos no formato PRPS (Phase Resolved Pulse Sequence) 47
4.3 - Redes Neurais utilizando a grade de pixels do gráfico 3D φxqxN 48
4.3.1 - Gráfico 3D φxqxN–refinamento com re-escalonamento em q 50
4.4 - Utilização de uma topologia com 2 camadas internas 52
4.5 - Análise dos resultados 56
5 - CONCLUSÃO 58
6 - REFERÊNCIAS 60
7 - ANEXO I 62

LISTA DE FIGURAS

Figura 1.1: Visualização de DP em base de tempo elíptica 2
Figura 1.2: Instrumento Tetex 9120 3
Figura 1.3: Visualização da forma do pulso de uma DP 4
Figura 1.4: Formas de aplicação de tensão 5
Figura 1.5: Publicação FES International Ltd. 7
Figura 1.6: Tela do Equipamento ICM da Power Diagnosticx Systems 8
Figura 1.7: Tela do equipamento DMS – Diagnostic Monitoring Systems 8
Figura 1.8: Topologia da molécula de SF_6 9
Figura 1.9: Comparativo da rigidez do SF6 em função da pressão 10
Figura 1.10: Ábaco Pressão x Temperatura x densidade 11
Figura 1.11: Subestação isolada a gás SF_6, Usina de Itaipu 12
Figura 1.12: Acoplador para medição de descargas parciais 13
Figura 1.13: Principais anormalidades que geram descargas parciais 13
Figura 2.1: Enlace entre os diversos tipos de medidores e as aplicações 20
Figura 2.2: Sistemas que aprendem vs. Sistemas Especialistas 22
Figura 3.1: Distribuição Hn(φ) 26
Figura 3.2: Distribuição Hqn(φ) 26
Figura 3.3: Formas típicas de distribuição e respectivos valores de Sk e Ku 28
Figura 3.4: ΔU e Δφ em pulsos seqüenciais de Descarga Parcial 31
Figura 3.5: Histograma de freqüência para ΔU 32
Figura 3.6: Histograma de freqüência para ΔU/Δφ 32
Figura 3.7: Gráfico 3D Hn(φ,q) 33
Figura 4.1: Topologia da rede neural do processamento 4.1 37
Figura 4.2: Topologia da rede neural do processamento 4.1 na representação gráfica da "nntool" do MatLab 38
Figura 4.3: Variáveis de entrada processamento 4.1 Arq.FE01 39
Figura 4.4: Gráfico com valores da SSE para treinamento da rede neural relativa à identificação do defeito eletrodo flutuante 40
Figura 4.5: Variáveis de entrada processamento 4.1- Arq.FE46 43
Figura 4.6: Variáveis de entrada processamento 4.1.1- Arq.FE46 44
Figura 4.7: Variáveis de entrada processamento 4.1.2- Arq.FE01 46
Figura 4.8: Variáveis de entrada processamento 4.2- Arq.FE01 47
Figura 4.9: Variáveis de entrada processamento 4.3- Arq.FE01 49
Figura 4.10: Variáveis de entrada processamento 4.3.1- Arq.FE01 51
Figura 4.11: Topologia da rede neural do processamento 4.4 52
Figura 7.1: SSE Treinam. e Val. Process. 4.1- NN-FE-15x8x2 63
Figura 7.2: SSE Treinam. e Val. Process. 4.1- NN-FE-15x8x4x2 63
Figura 7.3: SSE Treinam. e Val. Process. 4.1- NN-FW-15x8x2 64
Figura 7.4: SSE Treinam. e Val. Process. 4.1- NN-FW-15x8x4x2 64
Figura 7.5: SSE Treinam. e Val. Process. 4.1- NN-NC-15x8x2 65

Figura 7.6: SSE Treinam. e Val. Process. 4.1- NN-NC-15x8x4x2 65
Figura 7.7: SSE Treinam. e Val. Process. 4.1- NN-PB-15x8x2 66
Figura 7.8: SSE Treinam. e Val. Process. 4.1- NN-PB-15x8x4x2 66
Figura 7.9: SSE Treinam. e Val. Process. 4.1- NN-PE-15x8x2 67
Figura 7.10: SSE Treinam. e Val. Process. 4.1- NN-PE-15x8x4x2 67
Figura 7.11: SSE Treinam. e Val. Process. 4.1- NN-SC-15x8x2 68
Figura 7.12: SSE Treinam. e Val. Process. 4.1- NN-SC-15x8x4x2 68
Figura 7.13: SSE Treinam. e Val. Process. 4.1- NN-VD-15x8x2 69
Figura 7.14: SSE Treinam. e Val. Process. 4.1- NN-VD-15x8x4x2 69
Figura 7.15: SSE Treinam. e Val. Process. 4.1.1- NN-FE-15x8x2 70
Figura 7.16: SSE Treinam. e Val. Process. 4.1.1- NN-FE-15x8x4x2 70
Figura 7.17: SSE Treinam. e Val. Process. 4.1.1- NN-FW-15x8x2 71
Figura 7.18: SSE Treinam. e Val. Process. 4.1.1- NN-FW-15x8x4x2 71
Figura 7.19: SSE Treinam. e Val. Process. 4.1.1- NN-NC-15x8x2 72
Figura 7.20: SSE Treinam. e Val. Process. 4.1.1- NN-NC-15x8x4x2 72
Figura 7.21: SSE Treinam. e Val. Process. 4.1.1- NN-PB-15x8x2 73
Figura 7.22: SSE Treinam. e Val. Process. 4.1.1- NN-PB-15x8x4x2 73
Figura 7.23: SSE Treinam. e Val. Process. 4.1.1- NN-PE-15x8x2 74
Figura 7.24: SSE Treinam. e Val. Process. 4.1.1- NN-PE-15x8x4x2 74
Figura 7.25: SSE Treinam. e Val. Process. 4.1.1- NN-SC-15x8x2 75
Figura 7.26: SSE Treinam. e Val. Process. 4.1.1- NN-SC-15x8x4x2 75
Figura 7.27: SSE Treinam. e Val. Process. 4.1.1- NN-VD-15x8x2 76
Figura 7.28: SSE Treinam. e Val. Process. 4.1.1- NN-VD-15x8x4x2 76
Figura 7.29: SSE Treinam. e Val. Process. 4.1.2- NN-FE-32x8x2 77
Figura 7.30: SSE Treinam. e Val. Process. 4.1.2- NN-FE-32x8x4x2 77
Figura 7.31: SSE Treinam. e Val. Process. 4.1.2- NN-FW-32x8x2 78
Figura 7.32: SSE Treinam. e Val. Process. 4.1.2- NN-FW-32x8x4x2 78
Figura 7.33: SSE Treinam. e Val. Process. 4.1.2- NN-NC-32x8x2 79
Figura 7.34: SSE Treinam. e Val. Process. 4.1.2- NN-NC-32x8x4x2 79
Figura 7.35: SSE Treinam. e Val. Process. 4.1.2- NN-PB-32x8x2 80
Figura 7.36: SSE Treinam. e Val. Process. 4.1.2- NN-PB-32x8x4x2 80
Figura 7.37: SSE Treinam. e Val. Process. 4.1.2- NN-PE-32x8x2 81
Figura 7.38: SSE Treinam. e Val. Process. 4.1.2- NN-PE-32x8x4x2 81
Figura 7.39: SSE Treinam. e Val. Process. 4.1.2- NN-SC-32x8x2 82
Figura 7.40: SSE Treinam. e Val. Process. 4.1.2- NN-SC-32x8x4x2 82
Figura 7.41: SSE Treinam. e Val. Process. 4.1.2- NN-VD-32x8x2 83
Figura 7.42: SSE Treinam. e Val. Process. 4.1.2- NN-VD-32x8x4x2 83
Figura 7.43: SSE Treinam. e Val. Process. 4.2- NN-FE-42x8x2 84
Figura 7.44: SSE Treinam. e Val. Process. 4.2- NN-FE-42x8x4x2 84
Figura 7.45: SSE Treinam. e Val. Process. 4.2- NN-FW-42x8x2 85
Figura 7.46: SSE Treinam. e Val. Process. 4.2- NN-FW-42x8x4x2 85
Figura 7.47: SSE Treinam. e Val. Process. 4.2- NN-NC-42x8x2 86
Figura 7.48: SSE Treinam. e Val. Process. 4.2- NN-NC-42x8x4x2 86
Figura 7.49: SSE Treinam. e Val. Process. 4.2- NN-PB-42x8x2 87

Figura 7.50: SSE Treinam. e Val. Process. 4.2- NN-PB-42x8x4x2 87
Figura 7.51: SSE Treinam. e Val. Process. 4.2- NN-PE-42x8x2 88
Figura 7.52: SSE Treinam. e Val. Process. 4.2- NN-PE-42x8x4x2 88
Figura 7.53: SSE Treinam. e Val. Process. 4.2- NN-SC-42x8x2 89
Figura 7.54: SSE Treinam. e Val. Process. 4.2- NN-SC-42x8x4x2 89
Figura 7.55: SSE Treinam. e Val. Process. 4.2- NN-VD-42x8x2 90
Figura 7.56: SSE Treinam. e Val. Process. 4.2- NN-VD-42x8x4x2 90
Figura 7.57: SSE Treinam. e Val. Process. 4.3- NN-FE-64x8x2 91
Figura 7.58: SSE Treinam. e Val. Process. 4.3- NN-FE-64x8x4x2 91
Figura 7.59: SSE Treinam. e Val. Process. 4.3- NN-FW-64x8x2 92
Figura 7.60: SSE Treinam. e Val. Process. 4.3- NN-FW-64x8x4x2 92
Figura 7.61: SSE Treinam. e Val. Process. 4.3- NN-NC-64x8x2.....93
Figura 7.62: SSE Treinam. e Val. Process. 4.3- NN-NC-64x8x4x2.....93
Figura 7.63: SSE Treinam. e Val. Process. 4.3- NN-PB-64x8x2 94
Figura 7.64: SSE Treinam. e Val. Process. 4.3- NN-PB-64x8x4x2 94
Figura 7.65: SSE Treinam. e Val. Process. 4.3- NN-PE-64x8x2 95
Figura 7.66: SSE Treinam. e Val. Process. 4.3- NN-PE-64x8x4x2 95
Figura 7.67: SSE Treinam. e Val. Process. 4.3- NN-SC-64x8x2.....96
Figura 7.68: SSE Treinam. e Val. Process. 4.3- NN-SC-64x8x4x2 96
Figura 7.69: SSE Treinam. e Val. Process. 4.3- NN-VD-64x8x2.....97
Figura 7.70: SSE Treinam. e Val. Process. 4.3- NN-VD-64x8x4x2 97
Figura 7.71: SSE Treinam. e Val. Process. 4.3.1- NN-FE-32x8x2 98
Figura 7.72: SSE Treinam. e Val. Process. 4.3.1- NN-FE-32x8x4x2 98
Figura 7.73: SSE Treinam. e Val. Process. 4.3.1- NN-FW-32x8x2 99
Figura 7.74: SSE Treinam. e Val. Process. 4.3.1- NN-FW-32x8x4x2 99
Figura 7.75: SSE Treinam. e Val. Process. 4.3.1- NN-NC-32x8x2.....100
Figura 7.76: SSE Treinam. e Val. Process. 4.3.1- NN-NC-32x8x4x2..... 100
Figura 7.77: SSE Treinam. e Val. Process. 4.3.1- NN-PB-32x8x2 101
Figura 7.78: SSE Treinam. e Val. Process. 4.3.1- NN-PB-32x8x4x2 101
Figura 7.79: SSE Treinam. e Val. Process. 4.3.1- NN-PE-32x8x2 102
Figura 7.80: SSE Treinam. e Val. Process. 4.3.1- NN-PE-32x8x4x2 102
Figura 7.81: SSE Treinam. e Val. Process. 4.3.1- NN-SC-32x8x2.....103
Figura 7.82: SSE Treinam. e Val. Process. 4.3.1- NN-SC-32x8x4x2..... 103
Figura 7.83: SSE Treinam. e Val. Process. 4.3.1- NN-VD-32x8x2..... 104
Figura 7.84: SSE Treinam. e Val. Process. 4.3.1- NN-VD-32x8x4x2 104

LISTA DE TABELAS

Tabela 2.1: Exemplos de ambientes e suas características 17
Tabela 4.1: Desempenho da aplicação 4.1 42
Tabela 4.2: Desempenho da aplicação 4.1.1 45
Tabela 4.3: Desempenho da aplicação 4.1.2 46
Tabela 4.4: Desempenho da aplicação 4.2 48
Tabela 4.5: Desempenho da aplicação 4.3 49
Tabela 4.6: Desempenho da aplicação 4.3.1 51
Tabela 4.7: Desempenho da aplicação 4.1 com RN15x8x4x2 53
Tabela 4.8: Desempenho da aplicação 4.1.1 com RN15x8x4x2 53
Tabela 4.9: Desempenho da aplicação 4.1.2 com RN32x8x4x2 54
Tabela 4.10: Desempenho da aplicação 4.2 com RN42x8x4x2 54
Tabela 4.11: Desempenho da aplicação 4.3 com RN64x8x4x2 55
Tabela 4.12: Desempenho da aplicação 4.3.1 com RN32x8x4x2 55
Tabela 4.13: Comparação de desempenho na taxa de classificação 57

RESUMO

A utilização da medição do valor de Descargas Parciais no dielétrico de equipamentos de alta tensão para avaliação da sua qualidade já é uma técnica consagrada, normatizada, e largamente utilizada em laboratórios de fabricantes e centros de pesquisa. A aplicação da mesma técnica para o monitoramento em tempo real de equipamentos isolados em SF_6, na condição operativa e energizados, tem um grande potencial, porém requer a superação de uma série de obstáculos.

Propostas de medições indiretas, diferentes da normatizada, visando superar os problemas com a instalação de divisores capacitivos, níveis de ruído ambiente e da tensão industrial vem sendo oferecidas no mercado.

Diante da opção de empresas do setor elétrico brasileiro por um equipamento desenvolvido pela "DMS" (Diagnostic Monitoring System – UK), cuja forma de aquisição e processamento não contempla a totalidade dos requisitos normatizados mas permite a sua detecção indireta, o presente trabalho se propõe a dar uma contribuição adicional, verificando se as informações disponibilizadas pelo equipamento da DMS, além de detectarem e permitirem uma quantificação relativa do valor das descargas parciais permitem, também a identificação do tipo de defeito encontrado.

Desta forma, o trabalho relata a escolha, a implementação e avaliação de técnicas de classificação propostas para ensaios normatizados de descargas parciais e sua associação a técnicas de redes neurais, como forma de estabelecer um reconhecimento automático de 07 tipos de defeitos característicos de equipamentos de alta tensão isolados em SF_6.

Os resultados obtidos mostram que as técnicas aplicadas obtiveram índices satisfatórios de classificação, requerendo, em alguns casos, refinamentos para adaptação às características específicas do equipamento da DMS.

ABSTRACT

The measurement of Partial Discharges in the dielectric media of high voltage equipment as a means of assessing its quality is a technique already established, standardized, and widely employed in factory laboratories and research centers. The application of the same equipment to on-line monitoring, in real time, of SF_6 insulated equipment, while energized and in operation, is very promising, although it has to overcome a series of obstacles.

Proposals for indirect measurements, which differ from the standardized ones, with a view to overcoming the problems being faced with the installation of capacitive dividers, environmental and industrial voltage noise levels, are being offered on the market.

Some utilities of the Brazilian electrical sector have chosen to use the monitoring system developed by "DMS" (Diagnostic Monitoring System - UK), whose form of data acquisition and processing does not completely fulfill all the standardized requirements, but performs an indirect detection of the partial discharges.

The present dissertation intends to make an additional contribution by verifying whether the information emitted by the DMS, as well as detecting and permitting a relative quantification of the values of the partial discharges, also permits the diagnostic identification of the types of abnormalities.

The dissertation reports the selection, implementation and appraisal of classification techniques proposed for standardized tests of partial discharges, and their association with neural networks, as a means for establishing the automatic recognition of 07 characteristic abnormalities in SF_6 gas insulated high voltage equipment.

The results demonstrate that the proposed techniques have obtained very satisfactory rates of classification, in some cases requiring refinements for adaptation to the specific characteristics of the DMS diagnostic equipment.

1 – INTRODUÇÃO

Neste capítulo será apresentado um breve histórico da evolução da técnica de medição de Descargas Parciais e sua aplicação específica em equipamentos isolados em SF_6 para então se definir a proposta da dissertação.

A avaliação do estado do isolamento de equipamentos elétricos de alta tensão através da medição do valor de descargas parciais vem evoluindo à medida em que a eletrônica e a informática possibilitam o desenvolvimento de instrumentos cada vez mais dotados de recursos e a custos menores.

"Sinais de descargas parciais (DP) têm sido estudados desde 1920 por Gemant e Philippof, que introduziram o conceito do circuito equivalente e da interpretação do fenômeno em cavidades internas ao isolamento sólido" [Borsi, 00].

"Descargas parciais representam um fenômeno importante para verificar o projeto e o isolamento elétrico de um sistema ou descrever o envelhecimento e avaliar a probabilidade de uma futura falha" [Stone, 00].

A sua medição em laboratório como ensaio de rotina já faz parte da especificação de compra da maioria dos equipamentos de alta-tensão sendo normatizada internacionalmente pela [IEC60.270, 98] e no Brasil também pela [NBR6940, 81].

Embora estas normas estabeleçam somente a medição do valor da descarga relativa em picocoulombs, "adicionalmente outras características, como o ângulo de fase dos pulsos de DP em relação a tensão do sistema, o número e a energia dos pulsos, são usadas para uma interpretação mais exata dos resultados e também para a avaliação de uma possível falha. Em muitos casos a localização da falta é também desejada" [Borsi, 00].

UNIVERSIDADE FEDERAL DE ITAJUBÁ
Biblioteca
MAUÁ
DIM

1.1 - Evolução da técnica de medição de DP

Segundo [Lalitha & Satish, 00], DP é um evento de descarga elétrica localizada numa região da estrutura de uma isolação. Este tipo de defeito pode ser inerente ao processo de fabricação ou se desenvolver durante o tempo de uso de determinado equipamento, independente dos maiores esforços e precauções na fabricação e manutenção. DP usualmente é evento pulsivo, com um tempo muito curto de subida e relativamente longo de queda, sendo que estes valores dependem do tipo de isolação. Quantificar DP em termos de carga aparente é muito usual e correlaciona bem com a degradação da isolação.

Na detecção clássica de DP os pulsos causados pelas descargas na amostra são vistos numa base de tempo elíptica(figura 1.1), onde "0" coincide com os zeros, "P" com a crista positiva e "N" com a crista negativa da tensão senoidal de teste [Kreuger *et al*, 93].

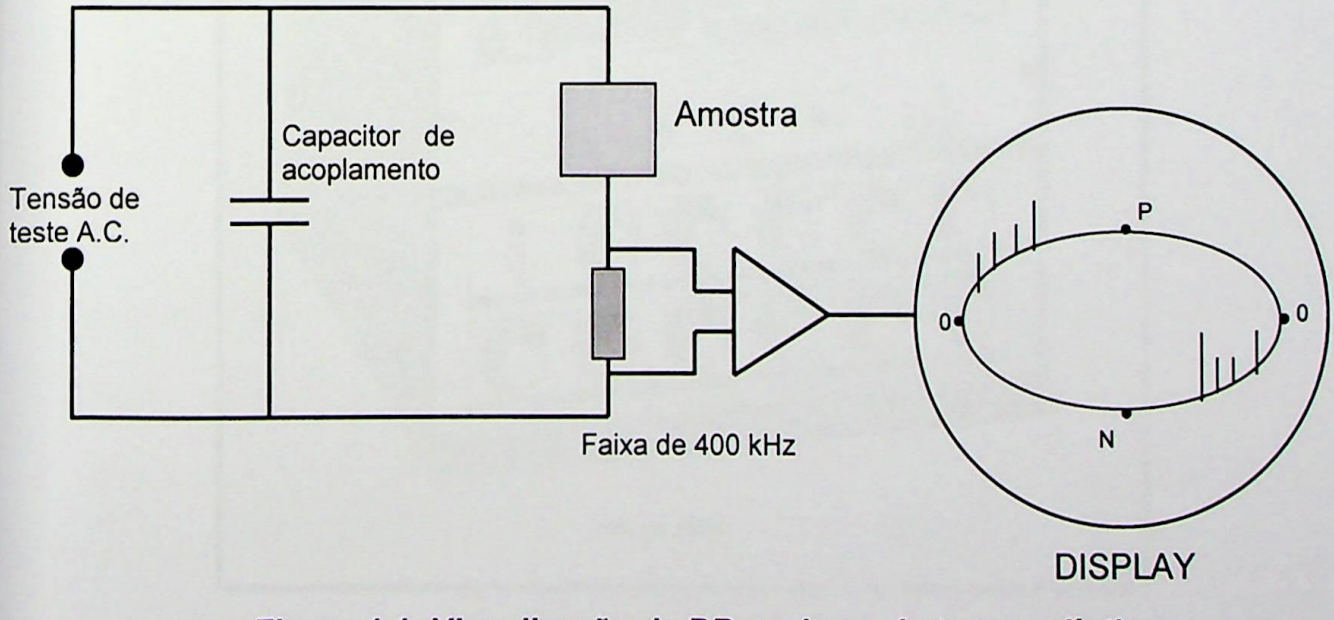


Figura 1.1- Visualização de DP em base de tempo elíptica [Kreuger *et al*, 93]

Na medição de DP normatizada pela [IEC60.270, 98] e [NBR6940, 81] utiliza-se de equipamento específico integrando um voltímetro de pico para a quantificação de descarga aparente (q), e de um osciloscópio para a identificação do ângulo de fase (ϕ).

Na figura 1.2 vê-se em detalhe o equipamento Tetex-9120, onde pode-se observar o voltímetro de pico, "meter display", e a tela do osciloscópio formando a elipse onde se identifica o ângulo "ϕ" das descargas.

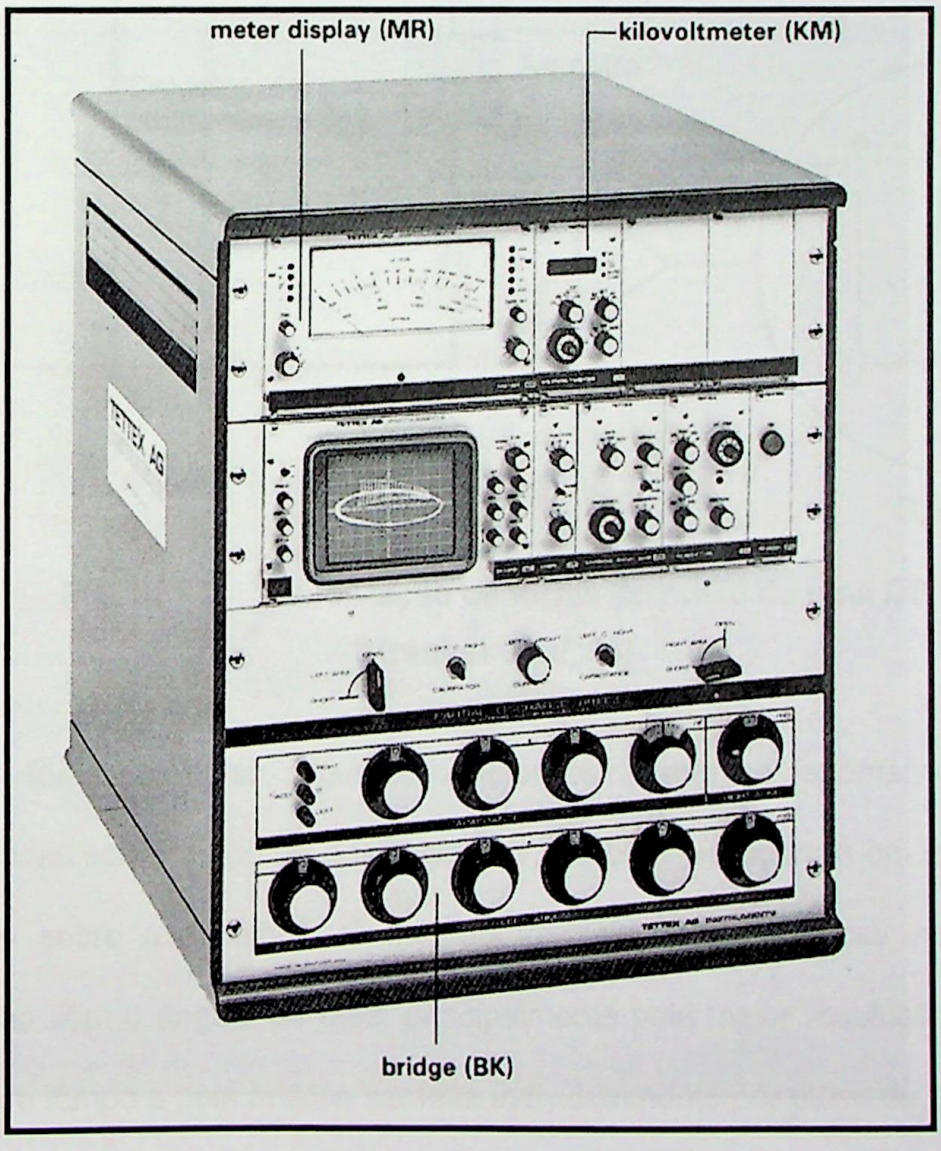


Figura 1.2 – Instrumento Tetex 9120 [Tettex, 85]

Segundo [Kreuger *et al,* 93], também foram obtidos resultados interessantes com a detecção da forma dos pulsos de DP, usando equipamentos na faixa de 500 a 1000 MHz.

Na figura 1.3 tem-se o circuito de medição utilizado para obter a verdadeira forma do pulso de DP e um exemplo de sua visualização através de um gráfico com ordenada em milivolts e abscissa em nanosegundos.

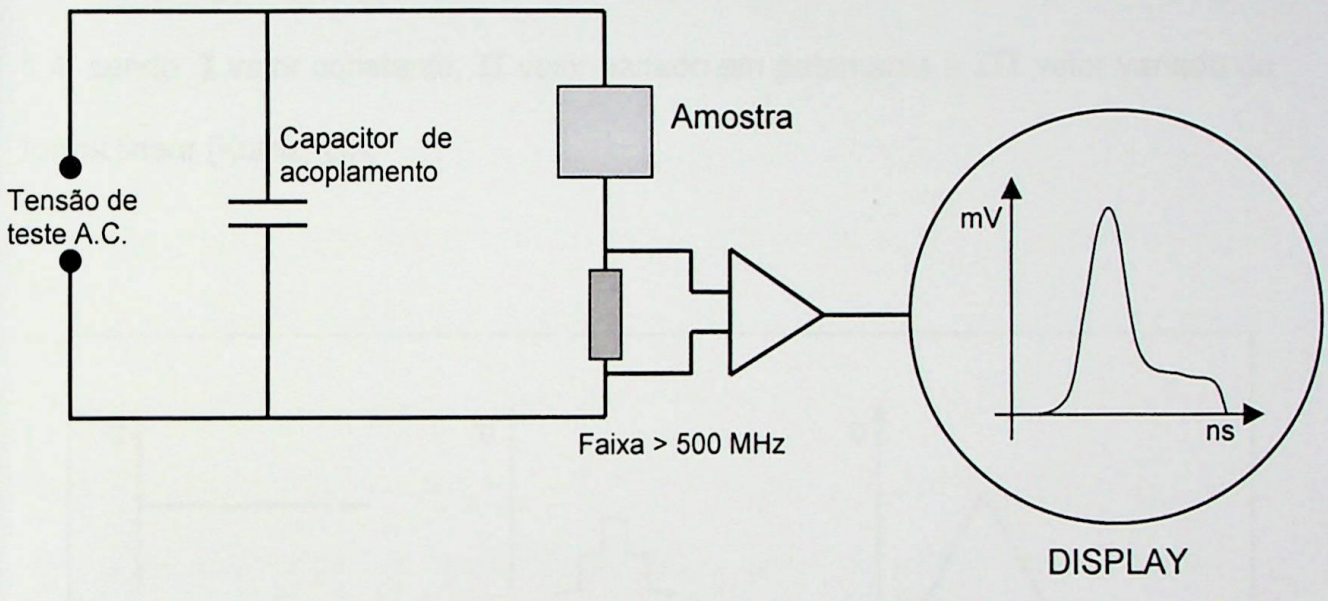


Figura 1.3 – Visualização da forma do pulso de uma DP [Kreuger *et al*, 93]

Da forma do pulso, algumas conclusões quanto ao fenômeno podem ser estabelecidas sobre o tipo de descarga, tais como se ela ocorreu em meio gasoso, dentro ou sobre o dielétrico. O método traz algumas diferenças em relação à associação com o ângulo de fase, principalmente pela maior resolução necessária na base de tempo e pela análise ser feita individualmente por pulso de DP e não em um conjunto de pulsos.

A desvantagem deste método está na dificuldade para seu uso em aplicações industriais, tanto pelo alto custo dos equipamentos de medição, quanto pela maior sensibilidade necessária ao circuito de medição e consequentemente maior susceptibilidade aos ruídos de origem eletromagnética característicos de instalações como subestações e plantas industriais . Além disso, distorções no pulso durante o caminho entre o defeito e o detector descaracterizam totalmente a informação.

Outra variável na medição de descargas parciais é a forma de aplicação da tensão, que pode ser aplicada de três formas básicas conforme ilustrado na figura 1.4, sendo **I** valor constante, **II** valor variado em patamares e **III** valor variado de forma linear [Kranz, 00].

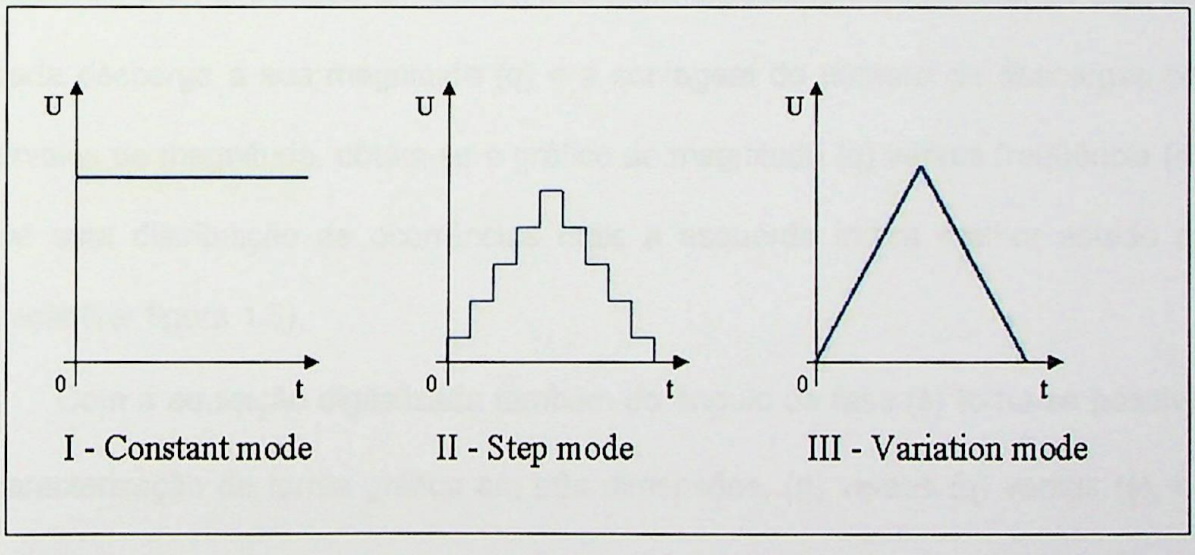


Figura 1.4 – Formas de aplicação de tensão [Kranz, 00]

No modo **I**, "Constant mode", o diagnóstico fica limitado especialmente nos casos das descargas estarem ocorrendo próximo a tensão de início (inception voltage) ou da Tensão de extinção (extinction voltage).

O modo **III**, "Variation mode", permite o diagnóstico em uma forma mais detalhada. Caso o sistema de regulação de tensão produza ele mesmo descargas durante a variação de tensão, tem-se de optar pelo modo **II**, "Step mode".

Naturalmente, o monitoramento on-line fica restrito a ser realizado com a tensão de operação, **I** "constante mode", uma vez que a estabilidade da tensão é um dos fatores de qualidade da tensão do sistema, enquanto em pesquisas pode-se utilizar os modos com variação da tensão.

A partir da década de 1980, com a utilização de microprocessadores acoplados ao sistema de medição, tornou-se possível a captura de informação adicional de grande importância, que é a contagem do número de descargas (n), associada inicialmente a sua caracterização por intensidade (q), e posteriormente também ao ângulo de fase (ϕ). Com a aquisição digitalizada, possibilitando associar a cada descarga a sua magnitude (q) e a contagem do número de descargas por intervalos de magnitude, obtém-se o gráfico de magnitude (q) versus freqüência (n), onde uma distribuição de ocorrências mais a esquerda indica melhor estado da isolação(ver figura 1.5).

Com a aquisição digitalizada também do ângulo de fase (ϕ) torna-se possível a caracterização de forma gráfica em três dimensões, (n) versus (q) versus (ϕ), ou ainda também suas variações bidimensionais (q) versus (ϕ), e (n) versus (ϕ).

Um formato padrão para gravar dados de DP em subestações isoladas a gás (GIS) foi proposto pelo grupo CIGRE "Task Force 15.03.08" [Huecker *et al*, 98]. Sendo uma estrutura aberta, o formato CIGRE pode ser usado para todos os instrumentos de medição e/ou equipamentos para análise/diagnóstico.

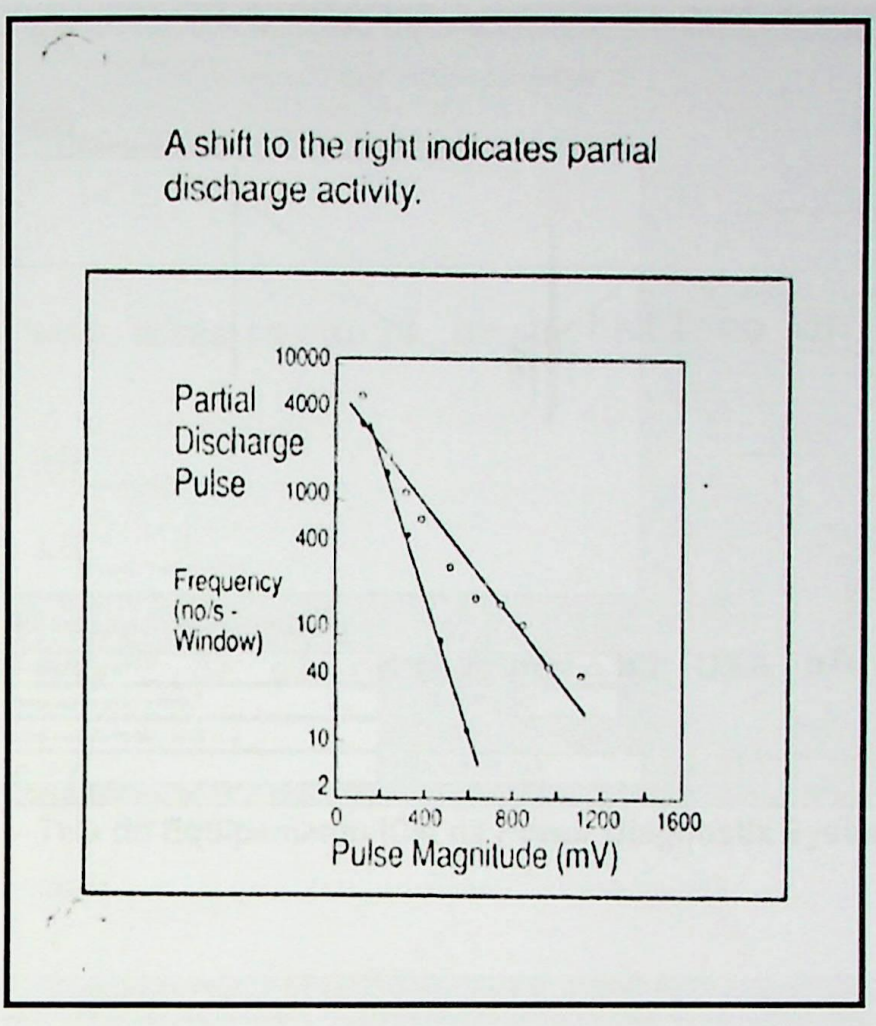


Figura 1.5 – Publicação FES International Ltd. [FES, 85]

Na figura 1.6 a seguir, tem-se a reprodução da tela do equipamento ICM da Power Diagnostix Systems GmbH, com um gráfico (ϕ - abcissa) versus (q - ordenada) versus (n - graduação de cor).

O aumento da capacidade de aquisição e processamento dos equipamentos digitais tornou possível também a identificação do tempo de ocorrência de cada descarga, permitindo assim a sua visualização seqüencial e fornecendo um parâmetro a mais para auxiliar a sua análise.

Na figura 1.7 visualiza-se a tela do equipamento da DMS, "Diagnostic Monitoring Systems Ltd", com gráfico (ϕ - abcissa) versus (q – ordenada vertical) versus (seqüência temporal de ciclos – ordenada diagonal).

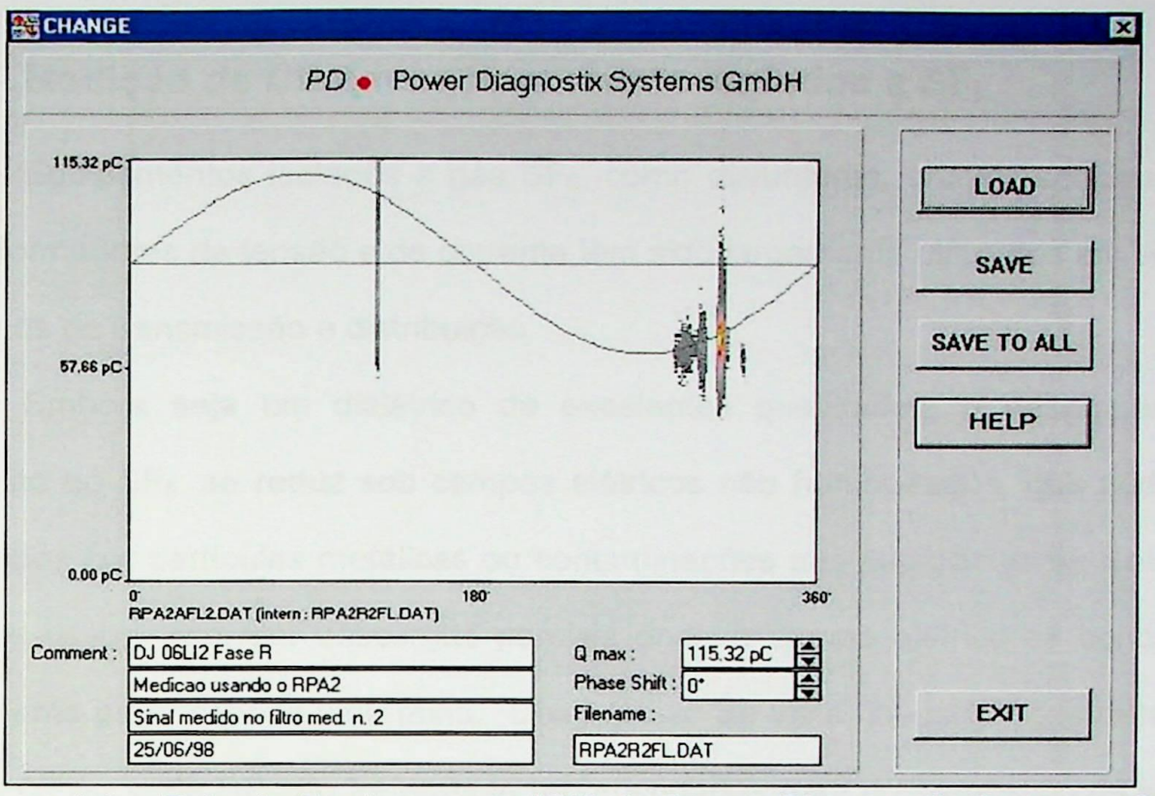


Figura 1.6 – Tela do Equipamento ICM da Power Diagnostix Systems GmbH

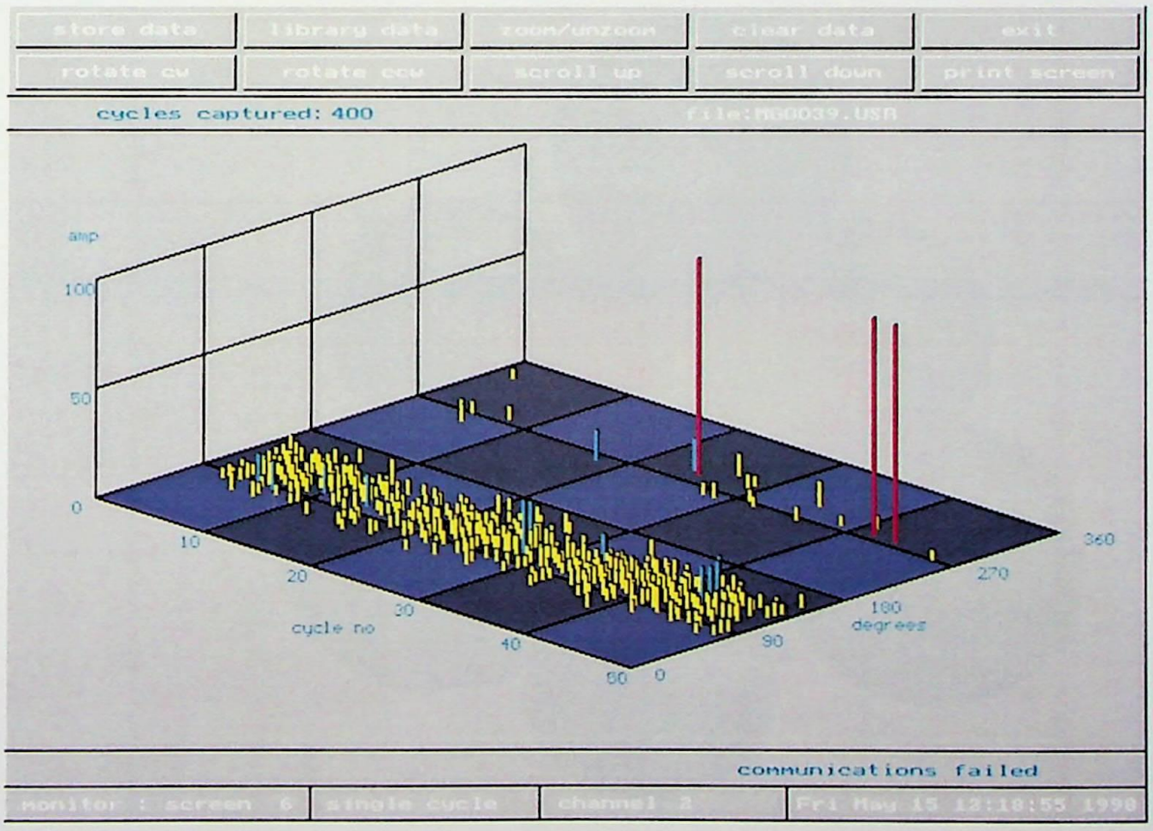


Figura 1.7 – Tela do equipamento DMS – Diagnostic Monitoring Systems Ltd

1.2 – Medição de DP em equipamentos isolados a SF_6

Equipamentos isolados a gás SF_6, como disjuntores, chaves seccionadoras, transformadores de tensão e de corrente têm sido largamente utilizados em sistemas elétricos de transmissão e distribuição.

Embora seja um dielétrico de excelentes qualidades, o desempenho da isolação do SF_6 se reduz sob campos elétricos não homogêneos, que podem ser causados por partículas metálicas ou contaminações nas superfícies de isoladores. Nestes casos, ocorrem descargas parciais onde o campo elétrico se concentra e finalmente pode ocorrer uma falha. Deste ponto de vista, investigações detalhadas do mecanismo de DP são fortemente recomendadas para o diagnóstico da isolação e uma previsão confiável de seu tempo de vida [Takahashi *et al*, 00].

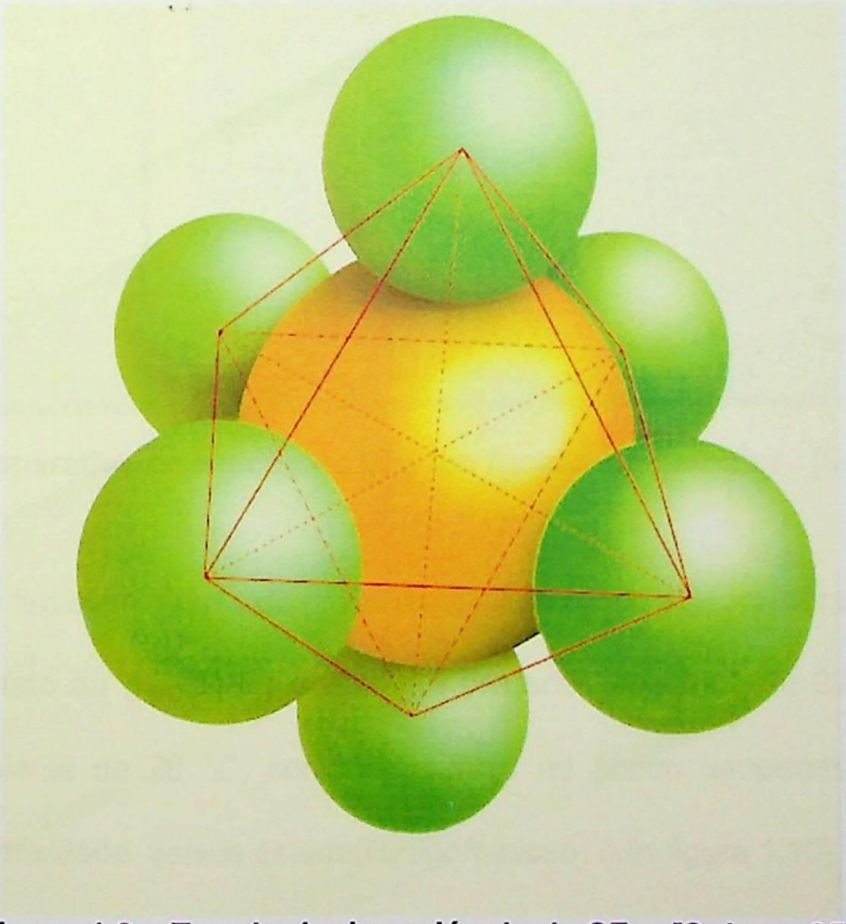


Figura 1.8 – Topologia da molécula de SF_6 - [Solvay, 95]

A molécula do gás SF_6 tem a geometria de um octaedro, com um átomo de flúor em cada vértice e um átomo de enxofre ao centro (figura 1.8). Pela sua alta eletronegatividade, tem excelente desempenho na extinção do arco elétrico. A rigidez dielétrica do gás é função da sua pressão (figura 1.9), chegando a ser superior a do óleo mineral isolante quando utilizado a uma pressão acima de 2,8 bar.

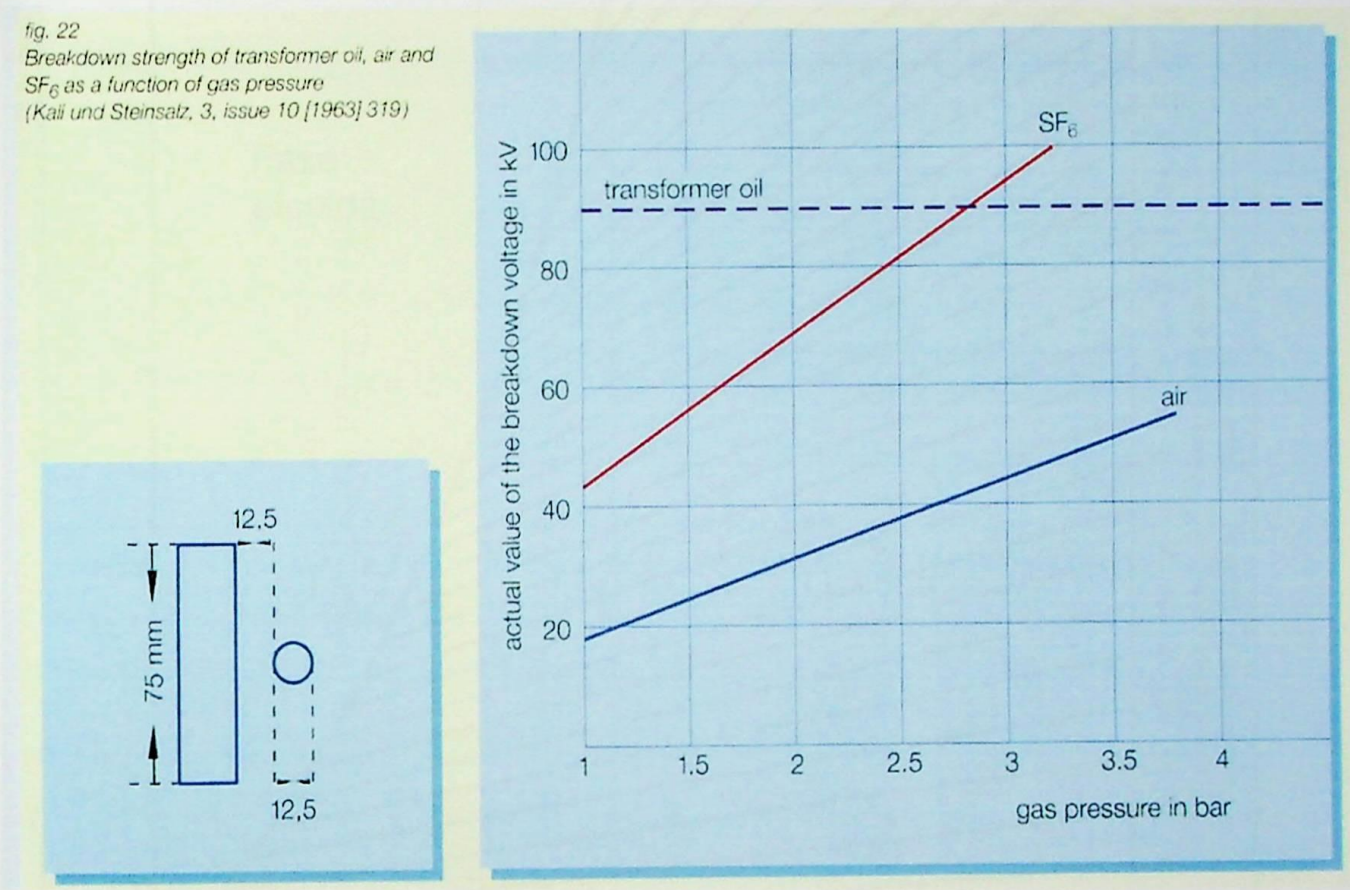


Figura 1.9 – Comparativo da rigidez do SF6 em função da pressão - [Solvay, 95]

Como fator limitante do uso de pressões mais altas para se melhorar a rigidez dielétrica está o fato do gás se liqüefazer em pressões próximas de 22 bar para temperatura ambiente de 20 °C, conforme curvas no ábaco temperatura versus pressão versus densidade versus estado(líquido/gasoso) (ver figura 1.10).

As pressões normalmente utilizadas nos equipamentos vão da faixa de 4 a 8 bar para temperatura de 20 °C.

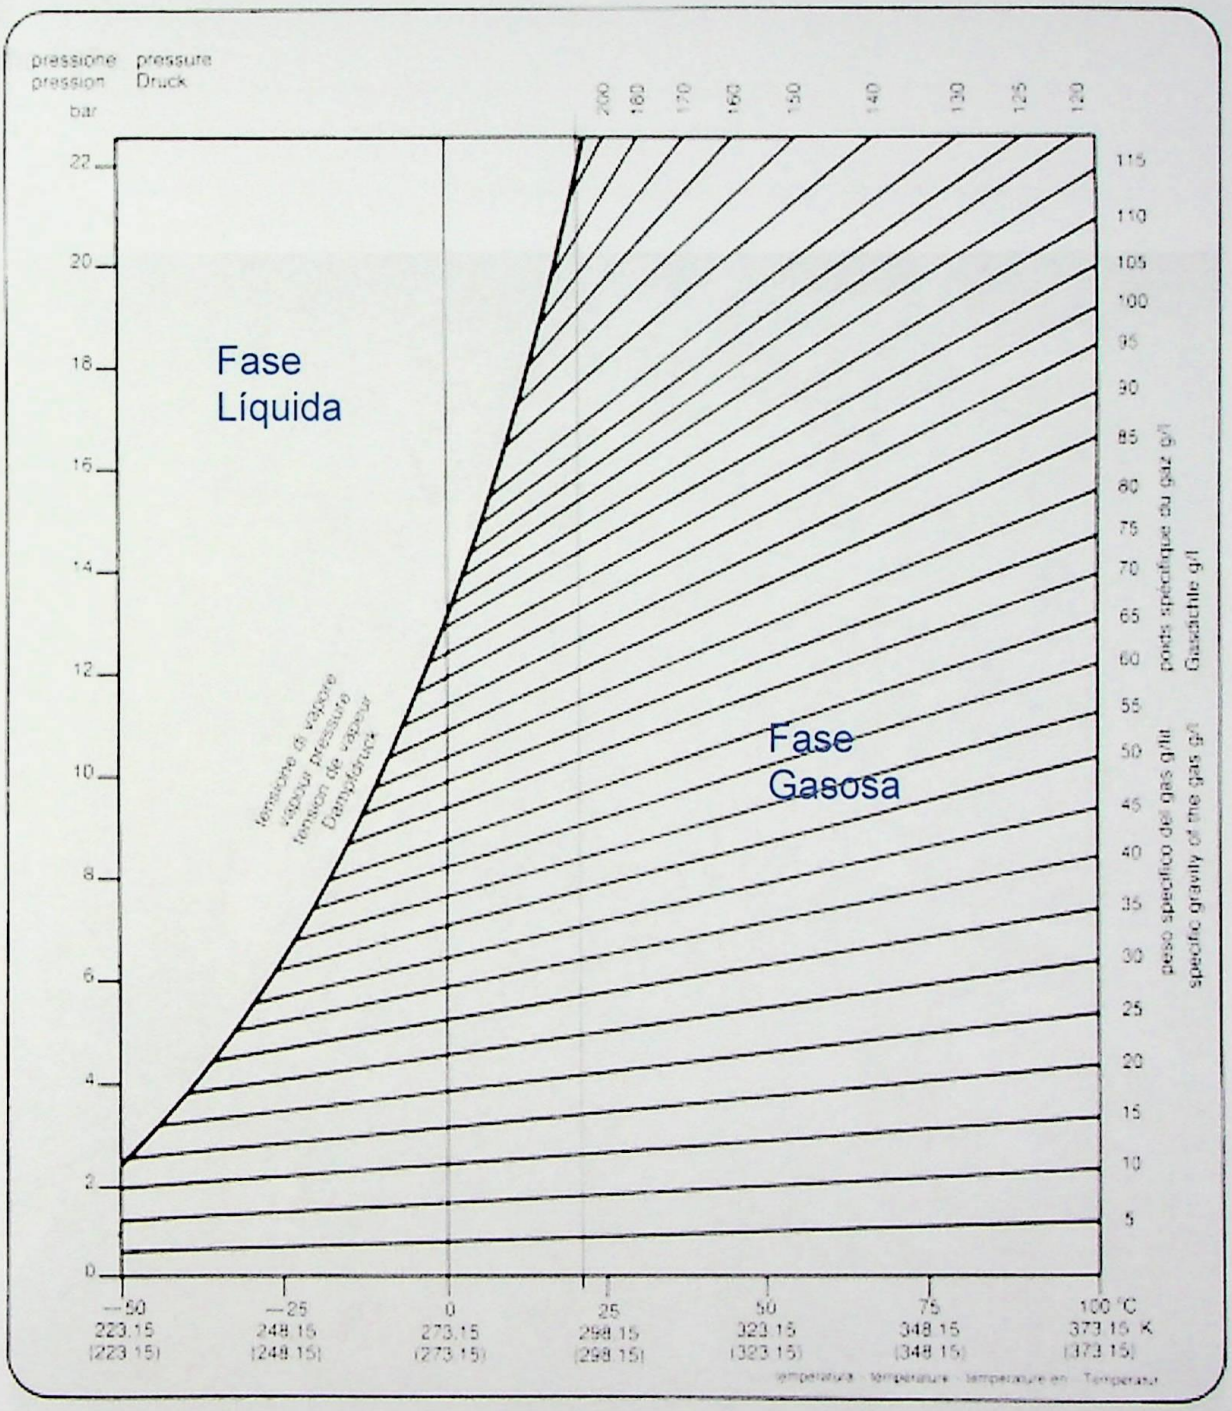


Figura 1.10 – Ábaco pressão x temperatura x densidade

[ESAFLON-AUSIMONT, 99]

Em uma subestação isolada a SF_6(figura 1.11), todos os componentes estão sob um revestimento metálico para conter o gás sob pressão, chamado de invólucro. Para se efetuar as medições de DP utiliza-se acopladores(figura 1.12), que atuam como sensores permitindo assim a detecção das descargas pelo sistema de medição.



Figura 1.11 – Subestação isolada a gás SF_6, Usina de Itaipu

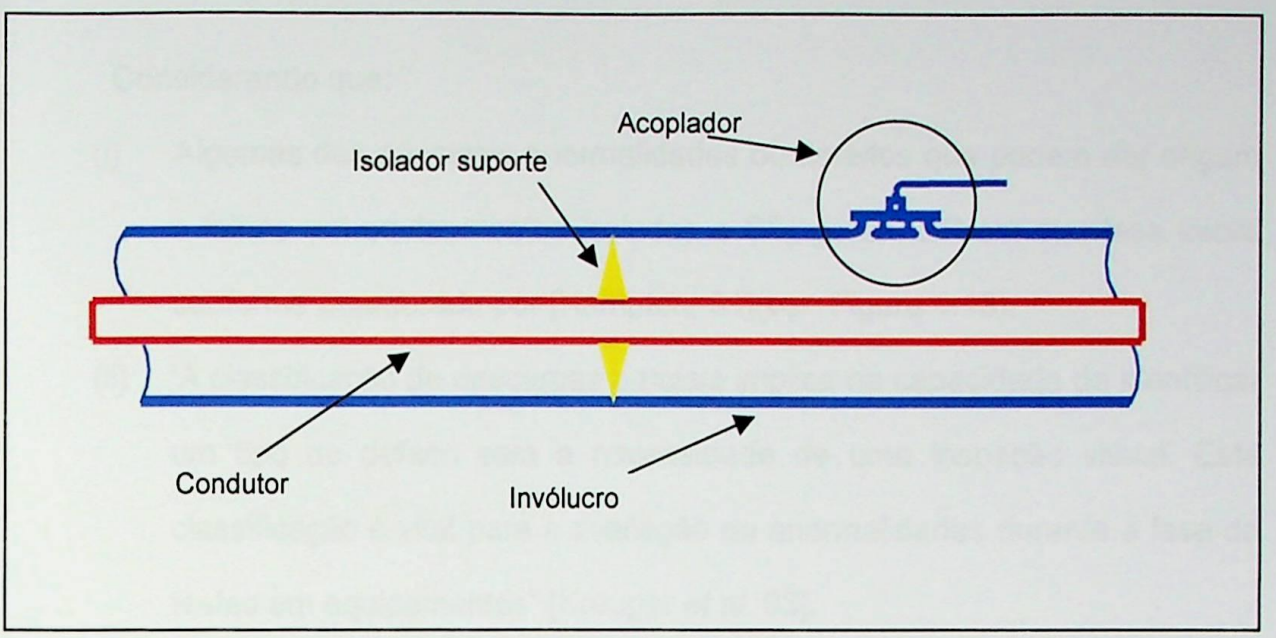


Figura 1.12 – Acoplador para medição de descargas parciais

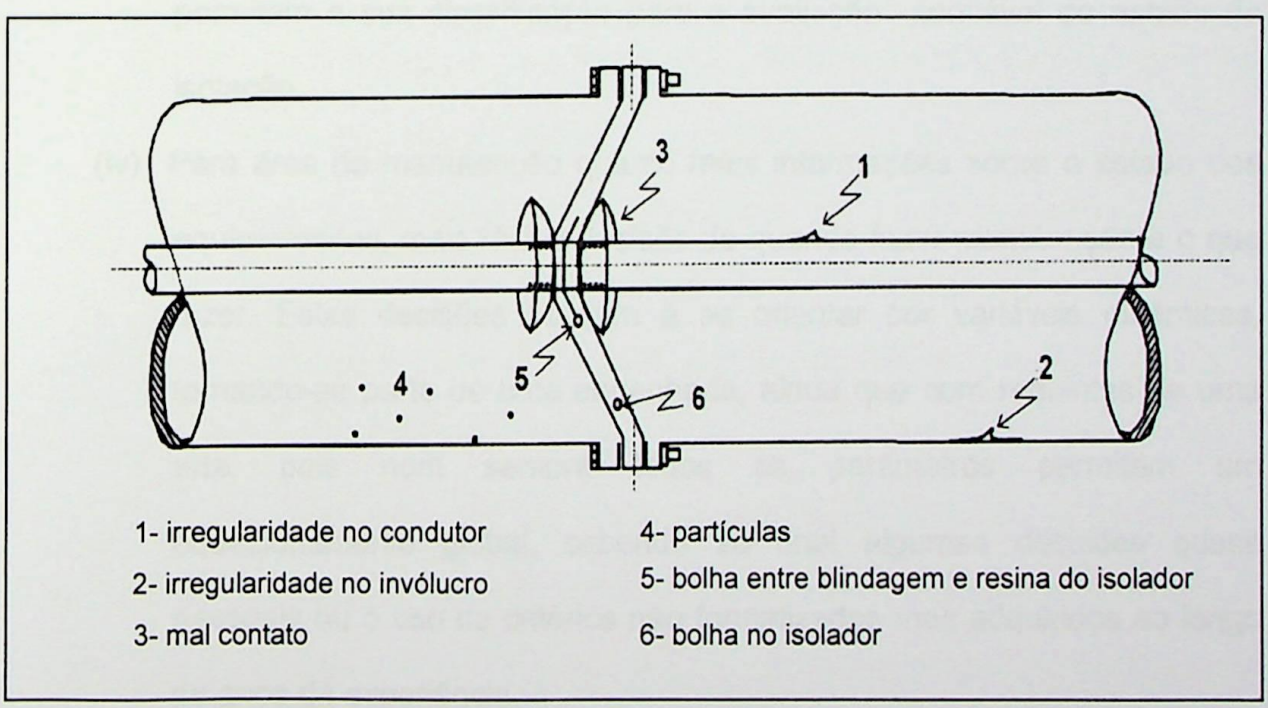


Figura 1.13 – Principais anormalidades que geram descargas parciais [Hampton, 01]

1.3 – Definição do problema

Considerando que:

(i) Algumas das principais anormalidades ou defeitos que podem dar origem a falhas em equipamentos isolados a SF_6 geram DP em sua fase inicial conforme enumerado por [Hampton, 01](ver Figura 1.13).

(ii) "A classificação de descargas parciais implica na capacidade de identificar um tipo de defeito sem a necessidade de uma inspeção visual. Esta classificação é vital para a avaliação de anormalidades durante a fase de testes em equipamentos" [Kreuger *et al*, 93].

(iii) À medida em que a evolução dos instrumentos de medição permite a aquisição de novos parâmetros, e com particularidades na sua formatação, surge a necessidade de se estabelecer os padrões que permitam a sua classificação para a avaliação confiável do estado da isolação.

(iv) Para área de manutenção quanto mais informações sobre o estado dos equipamentos, mais fácil a decisão de quando fazer manutenção e o que fazer. Estas decisões passam a se orientar por variáveis dinâmicas, tornando-se parte de uma engenharia, ainda que com requintes de uma arte, pois nem sempre todos os parâmetros permitem um equacionamento global, cabendo ao final algumas decisões quase pessoais ou o uso de critérios não formalizados mas adquiridos ao longo de anos de experiência.

(v) O uso de redes neurais para o reconhecimento automático de padrões[Bishop, 98] apresenta-se como uma das alternativas de maior

aplicação na área de engenharia tendo demonstrado ser capaz de absorver o "conhecimento" ou a "experiência" não formalizados.

(vi) [Kranz, 00] adverte que "Considerando diagnósticos baseados em computadores para sistemas complexos, somente se terá sucesso com inteligência artificial quando o diagnóstico obtido for mais confiável que o do engenheiro especialista". Em [Gulski & Krivda, 93] tem-se a indicação do uso de ferramentas baseadas em redes neurais para a classificação de descargas parciais atingindo os níveis de desempenho sugeridos por [Kranz, 00].

(vii) Hoje no Brasil 03 empresas, Copel, Gerasul e Itaipu, utilizam o sistema de monitoramento on-line por UHF desenvolvido pela DMS para detecção de DP, monitorando quatro subestações de 500 kV isoladas a SF_6, Salto Caxias(Copel), Foz do Areia(Copel), Ita(Gerasul) e Itaipu.

(viii) Torna-se oportuno ao meio acadêmico participar do esforço para encontrar as formas de aplicar a teoria, já comprovada em ensaios de laboratórios, nas aplicações industriais específicas, permitindo não só o aprimoramento da própria teoria como a sua divulgação e valorização, o que sem dúvida vem reforçar a imagem do meio acadêmico como fonte de soluções e aplicações para o setor elétrico brasileiro.

Neste contexto, para dar um maior suporte às decisões de engenharia de manutenção, assim como validar os conceitos desenvolvidos em modelos reduzidos de laboratório, propõe-se neste trabalho a aplicação e a avaliação do desempenho de redes neurais para a **CLASSIFICAÇÃO DE DESCARGAS PARCIAIS EM EQUIPAMENTOS ISOLADOS A SF_6 A PARTIR DE MONITORAMENTO ON-LINE POR UHF**.

2 – ESCOLHA DAS TÉCNICAS PARA APLICAÇÃO

Neste capítulo será apresentada uma breve síntese de aplicações das técnicas de Inteligência Artificial de forma geral e a seguir a escolha das técnicas aplicáveis na classificação de descargas parciais.

Nas últimas décadas, com o objetivo de emular através de um processo computacional a inteligência humana, várias áreas da ciência foram rebuscadas, desde os princípios filosóficos de Platão, 428 A.C., passando pela lingüística, psicologia, neurologia e a matemática.

Mesmo com esta sinergia entre as ciências ainda não tem-se a compreensão total da inteligência humana nem se chegou a sua emulação computacional por completo.

Considerando-se o proposto por [Russell & Norvig,95], tem-se a subdivisão da inteligência artificial em quatro categorias:

- Sistemas que pensam como humanos
- Sistemas que pensam racionalmente
- Sistemas que agem como humanos
- Sistemas que agem racionalmente

e considerando-se também as diferentes propriedades de um determinado ambiente quanto a:

- Acessibilidade (Acessível x Inacessível), um ambiente é acessível quando sensores podem detectar todos os aspectos relevantes para escolha ou ação;

- Determinismo (Determinístico x Não-determinístico), um ambiente é dito determinístico quando o próximo estado pode ser completamente definido pelo estado atual e a ação subsequente;
- Episódico (Episódico x Não-episódico), ambiente episódico é aquele no qual a ação do agente é baseada apenas nas circunstâncias do momento, não influenciando os próximos episódios;
- Estatismo (Estático x Dinâmico), o ambiente é dito dinâmico se está sujeito a mudanças no intervalo de processamento das informações;
- Discretismo (Discreto x Contínuo), um ambiente é dito discreto se existe um número limitado de situações e ações possíveis.

Na tabela 2.1 tem-se exemplos de ambientes e suas características segundo [Russell & Norvig, 95].

Tabela 2.1- Ambientes e suas características [Russel & Norvig, 95]

Ambiente	Característica				
	Acessível	Determinístico	Episódico	Estático	Discreto
Xadrez com relógio	sim	sim	Não	semi	sim
Xadrez sem relógio	sim	sim	Não	sim	sim
Poker	não	não	Não	sim	sim
Gamão	sim	não	Não	sim	sim
Diagnóstico Médico	não	não	Não	não	não
Análise de Imagem	sim	sim	Sim	semi	não
Robô com blocos	não	não	Sim	não	não
Controlador de processos	não	não	Não	não	não
Tutorial de idiomas	não	não	Não	não	sim

Pode-se constatar que o estado da arte já permite que sistemas dedicados a áreas específicas alcancem níveis de desempenho superior a humanos com grau de conhecimento médio e se igualando ou até mesmo superando em algumas situações a humanos com grau de conhecimento considerado superior.

Os sistemas de inteligência artificial são classificados [Weiss & Kulikowski, 91] em duas categorias conforme a maneira de assimilação do conhecimento:

- Sistemas Especialistas ("Expert Systems")
- Sistemas que aprendem por treinamento ("Learning Systems")

A opção entre eles vai depender de características do ambiente, da maior disponibilidade de regras de conhecimento formalizadas ou de exemplos com classificação definida.

Para cumprir a proposta de avaliar o desempenho de técnicas de inteligência artificial aplicadas na classificação dos resultados das medições de DP obtidas no monitoramento on-line por UHF em equipamentos isolados a SF_6, vamos a seguir definir os objetivos do sistema, analisar as características do ambiente e em seguida fazer a escolha das técnicas para aplicação.

2.1- Objetivo do sistema

O objetivo do sistema é obter uma classificação do tipo de defeito que deu origem à medição apresentada e ainda o grau de confiabilidade para o diagnóstico obtido.

A classificação será baseada nos sete defeitos típicos abaixo:

1- PB (Protrusion on Busbar) Ponta no barramento

2- PE (Protrusion on Enclosure) Ponta no invólucro

3- FE (Floating Electrod) Eletrodo flutuante

4- FW (Free Wire) Partícula metálica livre

5- SC (Surface Contamination) Contaminação na superfície do isolador

6- VD (Void) Bolha no isolador

7- NC (Noise Contamination) Ruído na medição

A avaliação do sistema será baseada na sua capacidade de classificação e no grau de confiabilidade do resultado, pois para uso como ferramenta de suporte a engenharia de manutenção do sistema de Geração/Transmissão em 500 kV, os desdobramentos de decisões têm de ser ponderados em seus graus de risco e custo.

Além do grau de confiabilidade do resultado como critério primário para avaliação do desempenho das aplicações, usaremos também dois critérios secundários sugeridos por [Weiss & Kulikowski, 91] que são a velocidade de computação e a simplicidade da solução.

Desta forma a avaliação levará em conta 03 critérios por ordem de relevância:

1- Confiabilidade;

2- Tempo de computação;

3- Simplicidade da aplicação.

UNIVERSIDADE FEDERAL DE ITAJUBÁ
Biblioteca
MAUÁ
BIM
UNIFEI

2.2- Características do ambiente

O grupo da CIGRÉ, Task Force 15.03.08, [Huecker *et al*, 98], estabeleceu uma formatação de dados padrão para permitir o enlace entre os diversos tipos de instrumentos de medição de Descargas Parciais e as aplicações posteriores como análise e visualização através de planilhas convencionais como Microsoft Excel e Corel Quattro-Pro, Sistemas de análise/avaliação, e o armazenamento em bases de dados, conforme diagrama figura 2.1.

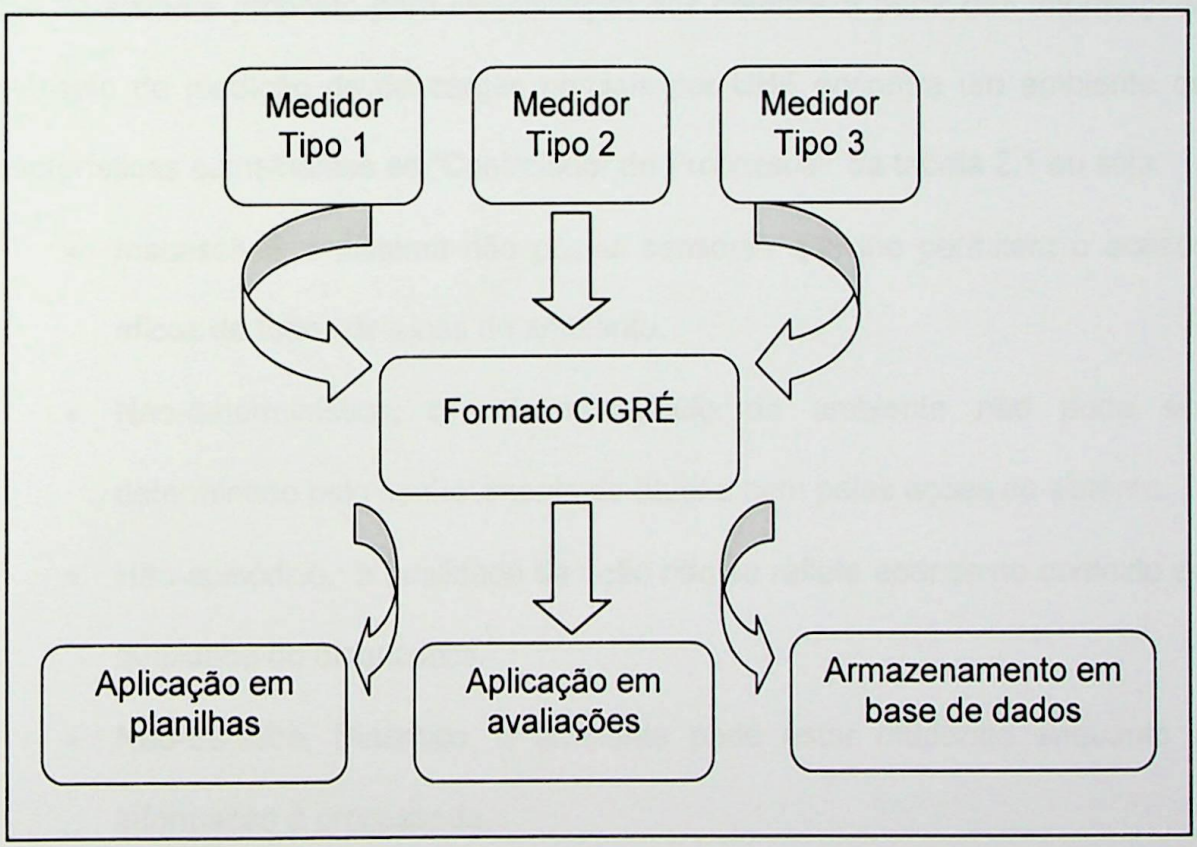


Figura 2.1 – Enlace entre os diversos tipos de medidores e as aplicações [Huecker et al, 98]

Desta forma o conhecimento do ambiente é feito através de um arquivo contendo uma seqüência de pulsos de DP, onde cada pulso($_p$) é caracterizado por:

"q_p" intensidade relativa em picocoulombs

"φ_p" ângulo de fase em relação ao ciclo da freqüência industrial

"t_p" tempo ou número seqüencial do ciclo

A principal vantagem desta caracterização é permitir a extração de informações para visualização gráfica tanto em relação ao ângulo de fase, "**P**hase **R**esolved **P**artial **D**ischarge - **PRPD**", quanto em relação ao tempo, "**P**hase **R**esolved **P**ulse **S**equence – **PRPS**".

O sistema proposto para classificação dos defeitos a partir das informações do ensaio de medição de descargas parciais por UHF encontra um ambiente de características semelhantes ao "Controlador de Processos" da tabela 2.1 ou seja:

- Inacessível, o sistema não possui sensores que lhe permitam o acesso eficaz de todos detalhes do ambiente.
- Não-determinístico, o próximo estado do ambiente não pode ser determinado pelo conhecimento do atual e nem pelas ações do sistema.
- Não-episódico, a qualidade da ação não se reflete apenas no contexto da qualidade do diagnóstico.
- Não-Estático, Dinâmico, o ambiente pode estar mudando enquanto a informação é processada.
- Não-Discreto, Contínuo, os valores das grandezas, "q_p", "φ_p", e "t_p", são a priori variáveis contínuas.

2.3- Técnicas mais adequadas para assimilação do conhecimento

Seguindo o critério proposto por [Weiss & Kulikowski, 91], a principal diferença entre um "Sistema Especialista" e um "Sistema que aprende por treinamento" está na maneira da obtenção da base de conhecimento.

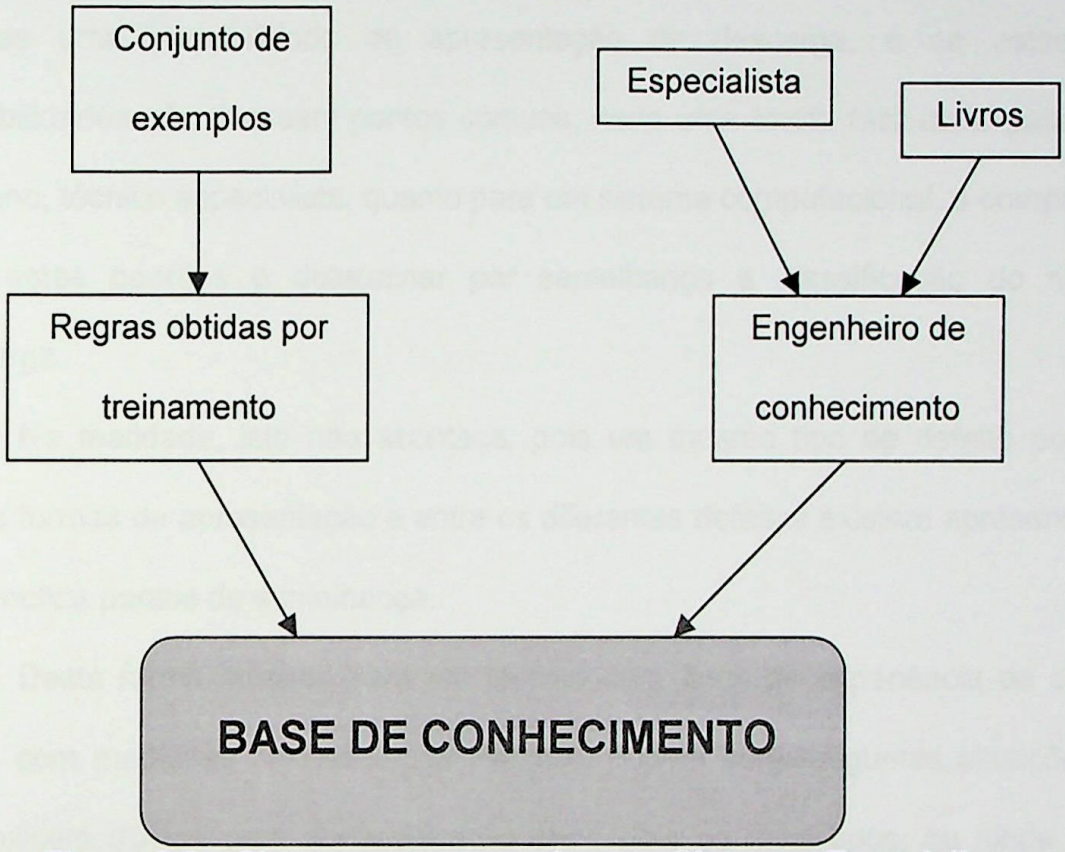


Figura 2.2 – Sistemas que aprendem vs. Sistemas Especialistas [Weiss & Kulikowski, 91]

No sistema especialista, a base de conhecimento é obtida através de sua interação com o mundo real através de um elemento humano, chamado de Engenheiro do Conhecimento ("Knowledge Engineer"), que é o responsável pela composição das regras da base de conhecimento. Já no sistema que aprende por treinamento a base de conhecimento é obtida por métodos computacionais através de treinamento sobre uma amostra de exemplos conhecidos.

[Weiss & Kulikowski, 91] sugerem ainda que na medida do possível o sistema ideal deva ser um sistema híbrido onde se possa aproveitar ao máximo o conhecimento formal existente e extrair regras adicionais dos exemplos disponíveis (ver figura 2.2).

Se para cada um dos sete defeitos típicos descritos no item 2.1 existisse apenas uma possibilidade de apresentação de descarga, e se estas sete possibilidades não tivessem pontos comuns, seria uma tarefa fácil tanto para o ser humano, técnico especialista, quanto para um sistema computacional, a comparação com estes padrões e determinar por semelhança a classificação do tipo de descarga.

Na realidade, isto não acontece, pois um mesmo tipo de defeito pode ter várias formas de apresentação e entre os diferentes defeitos existem apresentações com muitos pontos de semelhança.

Desta forma, mesmo para um técnico com anos de experiência de contato diário com medições de Descargas Parciais, podem surgir algumas situações em que existirá dúvida para a classificação entre dois ou mais tipos, ou ainda o não enquadramento em nenhum dos sete tipos.

A falta de um conjunto robusto de regras explícitas para a classificação de descargas parciais dificulta a elaboração de sistemas especialistas nesta área e leva à alternativa de buscar um conjunto representativo de amostras capaz de permitir a otimização de um sistema que aprenda por treinamento.

Redes Neurais [Gulski & Krivda, 93] têm a especial capacidade de "aprender" através de exemplos e têm demonstrado ser a técnica mais adequada para lidar com o fato de não existir um padrão único para cada tipo de defeito e ainda existir entre

eles certos pontos comuns, não sendo necessário o estabelecimento prévio de regras, mas simplesmente a obtenção de exemplos com diagnóstico conhecido para o "treinamento" ou "aprendizado" da Rede Neural.

Através da aplicação de operadores estatísticos na distribuição dos pulsos de descargas parciais, quer no formato **PRPD** ("**P**hase **R**esolved **P**artial **D**ischarge"), [Kreuger *et al,* 93], ou no formato **PRPS** ("**P**hase **R**esolved **P**ulse **S**equence"), [Lapp & Kranz 00], obtém-se variáveis escalares que permitem o treinamento de redes neurais introduzindo através da escolha destas variáveis um certo tipo de conhecimento, ou seja um pré-processamento.

Outra técnica possível utilizando redes neurais, [Satish & Zaengl, 94], é o treinamento utilizando diretamente a grade de pixels de um gráfico tridimensional, φx**q**x**N**, onde:

φ - ângulo de fase do pulso

q - intensidade relativa em picocoulombs do pulso

N - número de pulsos

A seguir faz-se o detalhamento da proposta inicial de, a partir de arquivos contento resultados da medição de DP em UHF de sete defeitos típicos em equipamentos elétricos isolados em SF_6, aplicar e avaliar o desempenho de técnicas de classificação utilizando redes neurais, aplicando e analisando o desempenho das seguintes alternativas:

(i) - Redes Neurais do tipo Perceptron de Múltiplas Camadas (PMC) utilizando operadores estatísticos no formato **PRPD**

(ii) - Redes Neurais PMC utilizando operadores estatísticos no formato **PRPS**

(iii) - Redes Neurais PMC utilizando a grade de pixels do gráfico 3D φx**q**x**N**

3 – APLICAÇÃO DAS TÉCNICAS SELECIONADAS

Neste capítulo serão descritas as aplicações das técnicas de classificação selecionadas no item 2.3.

A partir dos arquivos de medições disponíveis, compatíveis com o proposto pela CIGRÉ Task Force 15.03.08 [Huecker *et al*, 98], é necessário que se faça um processamento a fim de que sejam geradas as variáveis de entrada para o treinamento das redes neurais, e a otimização da topologia destas redes, para então se avaliar o desempenho quanto a capacidade de classificação conforme os sete defeitos típicos relacionados no item 2.1.

3.1 - Redes Neurais utilizando operadores estatísticos no formato PRPD (Phase Resolved Partial Discharge)

Do formato PRPD se obtêm as duas distribuições clássicas de descargas parciais, que são histogramas 2D, tendo como eixo das abscissas o ângulo de fase de 0 a 360 graus elétricos e como eixo das ordenadas o número de descargas ou o valor médio de descarga para cada intervalo em que se subdividiu o eixo das abscissas.

Utilizando a nomenclatura de [Kreuger *et al*, 93] denomina-se de **Hn(φ)** a distribuição do número de descargas (**n**) em função do ângulo de fase (φ) e de **Hqn(φ)** a distribuição das descargas médias (**q**), normalmente em pico-Coulombs [pC], também em função do ângulo de fase (φ). Ambas as distribuições contemplam uma série de descargas que são o resultado de um intervalo de medição que pode variar de segundos até horas de observação.

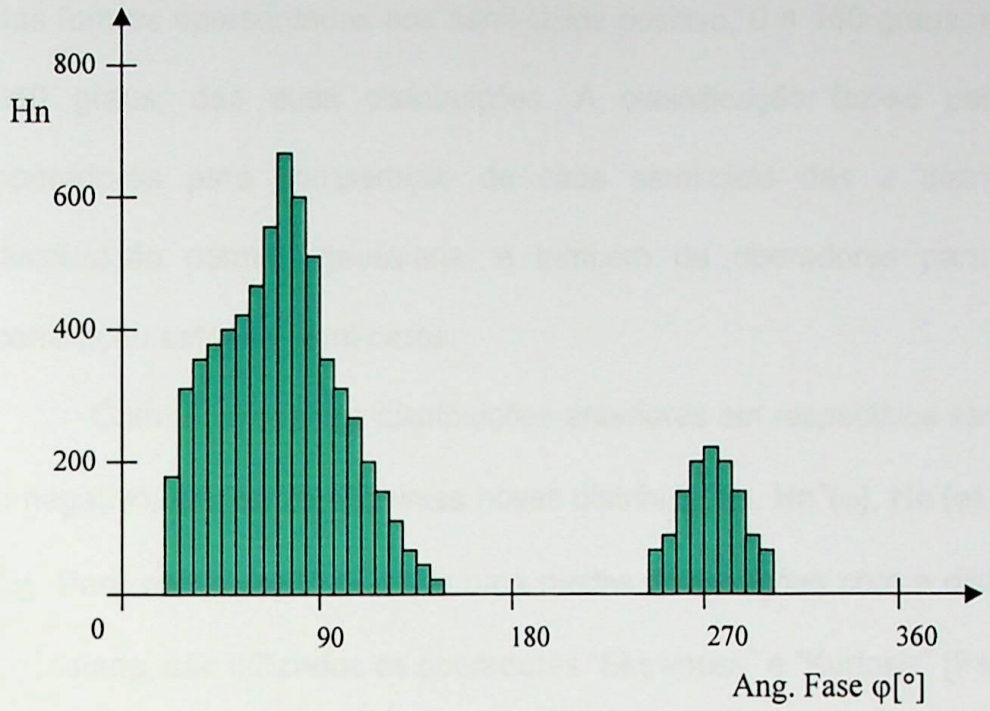


Figura 3.1- Distribuição Hn(φ)

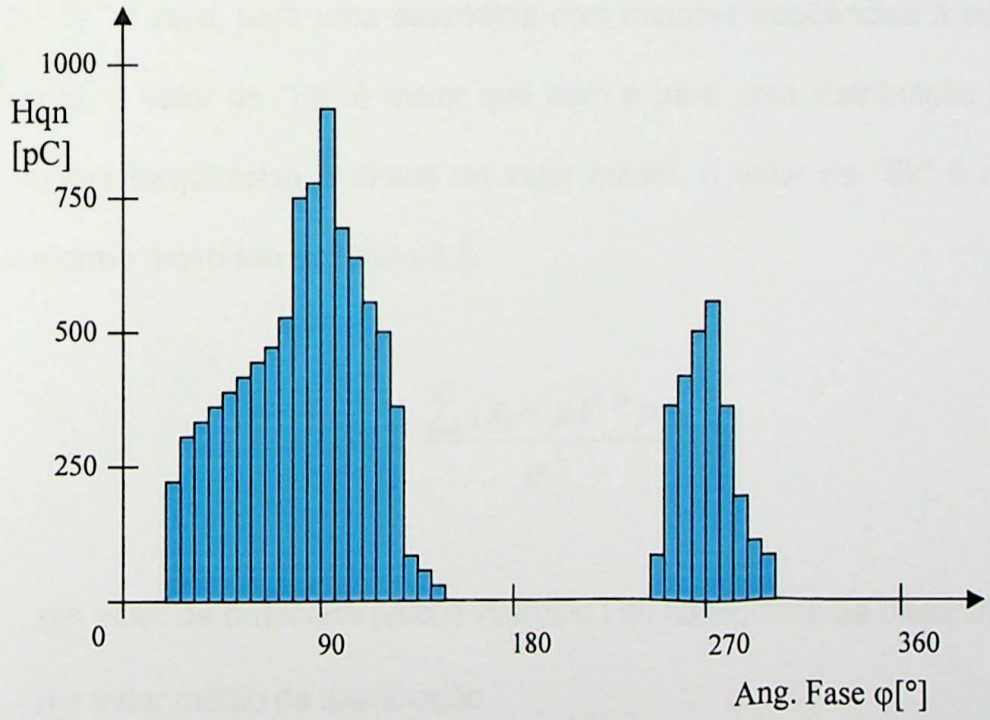


Figura 3.2 – Distribuição Hqn(φ)

Observando os histogramas das distribuições **Hn(φ)** e **Hqn(φ)**, mostrados nas figuras 3.1 e 3.2 respectivamente, fica intuitivamente claro a origem da metodologia proposta para classificação dos diversos tipos de defeitos através da caracterização

das formas apresentadas nos semi-ciclos positivo, 0 a 180 graus, e negativo 180 a 360 graus, das duas distribuições. A classificação faz-se pela aplicação de operadores para comparação de cada semi-ciclo das 2 distribuições com a distribuição normal, gaussiana, e também de operadores para comparação e correlação entre os semi-ciclos.

Com a divisão das distribuições anteriores em respectivos semi-ciclos positivo e negativo, tem-se as seguintes novas distribuições, $\mathbf{Hn^{+}(\varphi)}$, $\mathbf{Hn^{-}(\varphi)}$, $\mathbf{Hqn^{+}(\varphi)}$ e $\mathbf{Hqn^{-}(\varphi)}$. Para comparação de cada uma destas distribuições com a distribuição normal, gaussiana, são utilizados os operadores "Skewness" e "Kurtosis" [Papoulis, 91].

Com o operador "Skewness" obtém-se uma medida de quão assimétrica é a distribuição em relação ao seu valor médio. Para uma distribuição simétrica o valor de "Sk" é zero; para uma assimetria com maiores freqüências à esquerda do valor médio, o valor de "Sk" é maior que zero e para uma distribuição assimétrica com maiores freqüências à direita do valor médio, o valor de "Sk" é menor que zero, conforme mostrado na figura 3.3.

$$Sk = \frac{\sum (x_i - \mu)^3 * p_i}{\sigma^3} \qquad \textbf{(3.1)}$$

x_i = valor da ordenada para o intervalo i do histograma da distribuição

μ = valor médio da distribuição

p_i = probabilidade de ocorrência de x_i

σ = variância da distribuição

Com o operador "Kurtosis" obtém-se uma medida de quão concentrada é a distribuição em relação ao seu valor médio. Para a distribuição normal, o valor de "Ku" é zero. Para uma distribuição com maior concentração em torno do valor médio do que na distribuição normal, aparência "ponteaguda", o valor de "Ku" é maior que zero e para uma distribuição menos concentrada em torno do valor médio do que na distribuição normal, aparência "achatada" ou "larga", o valor de "Ku" é menor que zero(ver figura 3.3).

$$Ku = \frac{\sum (x_i - \mu)^4 * p_i}{\sigma^4} - 3 \qquad \textbf{(3.2)}$$

x_i = valor da ordenada para o intervalo i do histograma da distribuição

μ = valor médio da distribuição

p_i = probabilidade de ocorrência de x_i

σ = variância da distribuição

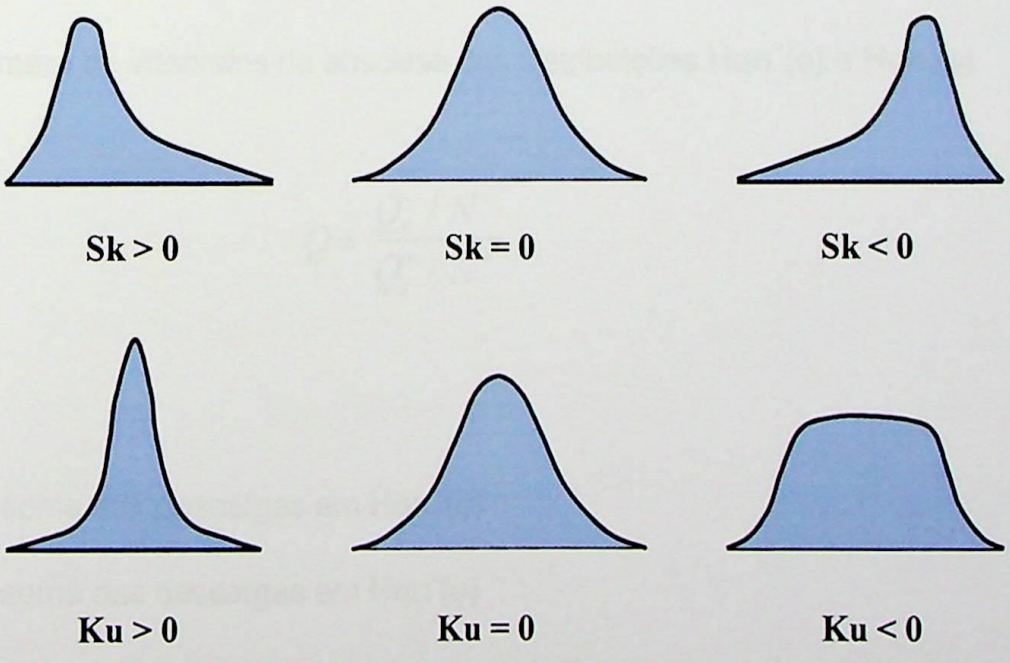


Figura 3.3 – Formas típicas de distribuição e respectivos valores de Sk e Ku

Para obtenção de variáveis através do correlacionamento das distribuições **$Hn^+(\varphi)$**, **$Hn^-(\varphi)$**, **$Hqn^+(\varphi)$** e **$Hqn^-(\varphi)$**, serão utilizados mais quatro operadores [Kreuger *et al*, 93] :

cc – correlação cruzada entre **$Hqn^+(\varphi)$** e **$Hqn^-(\varphi)$**

Q – fator de descarga

mcc – correlação cruzada modificada entre **$Hqn^+(\varphi)$** e **$Hqn^-(\varphi)$**

Pe – número de máximos locais de **$Hn^+(\varphi)$**, **$Hn^-(\varphi)$**, **$Hqn^+(\varphi)$** e **$Hqn^-(\varphi)$**

$$cc = \frac{\sum x_i y_i - \sum x_i \sum y_i / n}{\sqrt{\left[\sum x_i^2 - \left(\sum x_i\right)^2 / n\right] * \left[\sum y_i^2 - \left(\sum y_i\right)^2 / n\right]}} \qquad \textbf{(3.3)}$$

x_i = valor da ordenada para o intervalo i do histograma da distribuição **$Hqn^+(\varphi)$**

y_i = valor da ordenada para o intervalo i do histograma da distribuição **$Hqn^-(\varphi)$**

n = número de intervalos da abscissa das distribuições **$Hqn^+(\varphi)$** e **$Hqn^-(\varphi)$**

$$Q = \frac{Q_s^- / N^-}{Q_s^+ / N^+} \qquad \textbf{(3.4)}$$

onde,

Q_s^+ = soma das descargas em **$Hqn^+(\varphi)$**

Q_s^- = soma das descargas em **$Hqn^-(\varphi)$**

N^+ = soma do número de descargas em **$Hn^+(\varphi)$**

N^- = soma do número de descargas em **$Hn^-(\varphi)$**

$$mcc = Q * cc \tag{3.5}$$

Estes operadores aplicados nas quatro distribuições $\mathbf{Hn^+(\varphi)}$, $\mathbf{Hn^-(\varphi)}$, $\mathbf{Hqn^+(\varphi)}$ e $\mathbf{Hqn^-(\varphi)}$ resultam no conjunto das 15 variáveis abaixo:

1- Sk de $\mathbf{Hn^+(\varphi)}$

2- Sk de $\mathbf{Hn^-(\varphi)}$

3- Sk de $\mathbf{Hqn^+(\varphi)}$

4- Sk de $\mathbf{Hqn^-(\varphi)}$

5- Ku de $\mathbf{Hn^+(\varphi)}$

6- Ku de $\mathbf{Hn^-(\varphi)}$

7- Ku de $\mathbf{Hqn^+(\varphi)}$

8- Ku de $\mathbf{Hqn^-(\varphi)}$

9- Q

10- cc

11- mcc

12- Pe de $\mathbf{Hn^+(\varphi)}$

13- Pe de $\mathbf{Hn^-(\varphi)}$

14- Pe de $\mathbf{Hqn^+(\varphi)}$

15- Pe de $\mathbf{Hqn^-(\varphi)}$

Este conjunto de variáveis quando obtido a partir de medições dentro dos critérios normatizados, conforme mostrado por [Gulski & Krivda, 93] e [Kreuger *et al*, 93], permite o treinamento de redes neurais alcançando desempenho satisfatório e será utilizado a partir das medições de monitoramento por UHF para treinamento da rede neural PMC utilizando operadores estatísticos no formato PRPD.

3.2 - Redes Neurais utilizando operadores estatísticos no formato PRPS (Phase Resolved Pulse Sequence)

No formato PRPS tem-se a informação sobre a seqüência temporal da ocorrência das descargas. [Hoof & Patsh, 97] propõe o operador ΔU como forma de avaliar a freqüência das diferenças de tensão em descargas sucessivas(figura 3.4). Já [Lapp & Kranz, 00] sugerem o operador Δφ como forma de avaliar a freqüência das diferenças de ângulo entre descargas sucessivas, e a sua associação com ΔU na forma ΔU/Δφ(figura 3.4).

$$\Delta U = U(\varphi_i) - U(\varphi_{i-1}) \tag{3.6}$$

$$\Delta \varphi = \varphi_i - \varphi_{i-1} \tag{3.7}$$

$$\forall\, i = 2,\ldots,n$$

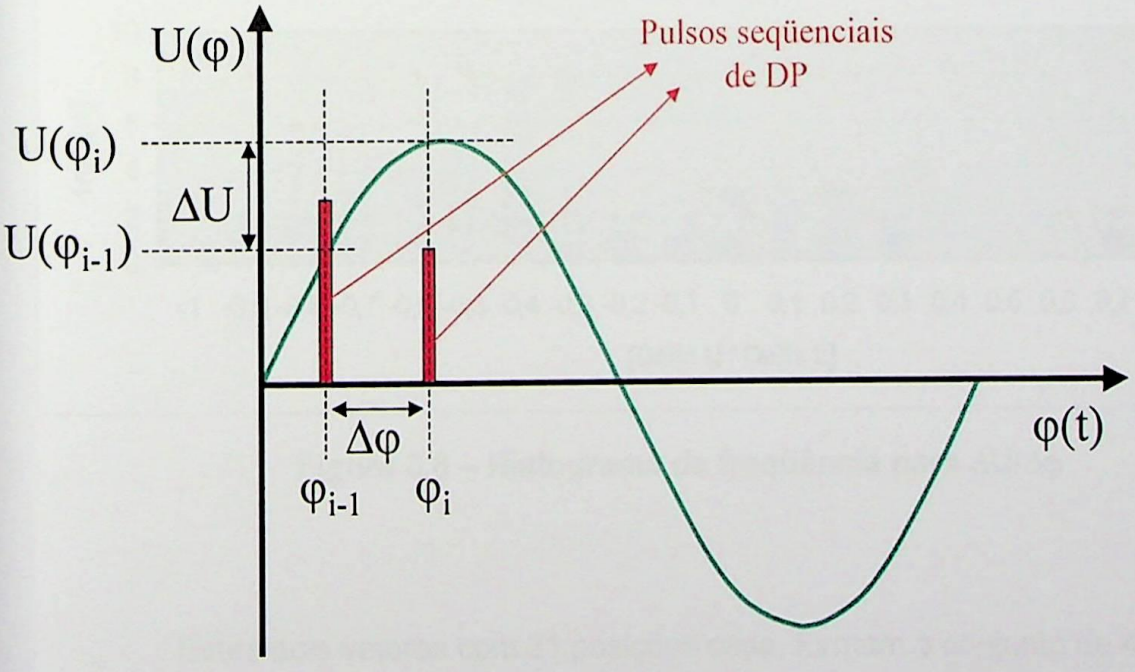


Figura 3.4 – ΔU e Δφ em pulsos seqüenciais de Descarga Parcial

Estes operadores, ΔU e $\Delta U/\Delta\varphi$, foram aplicados aos arquivos de medição de forma a gerar valores normalizados para valor máximo igual a +1, e valor mínimo igual a –1 e as freqüências armazenadas em vetores de 21 posições, visualizados como histogramas de freqüência com intervalos de 0,1 (entre –1,05 e +1,05), nas figuras 3.5 e 3.6 a seguir.

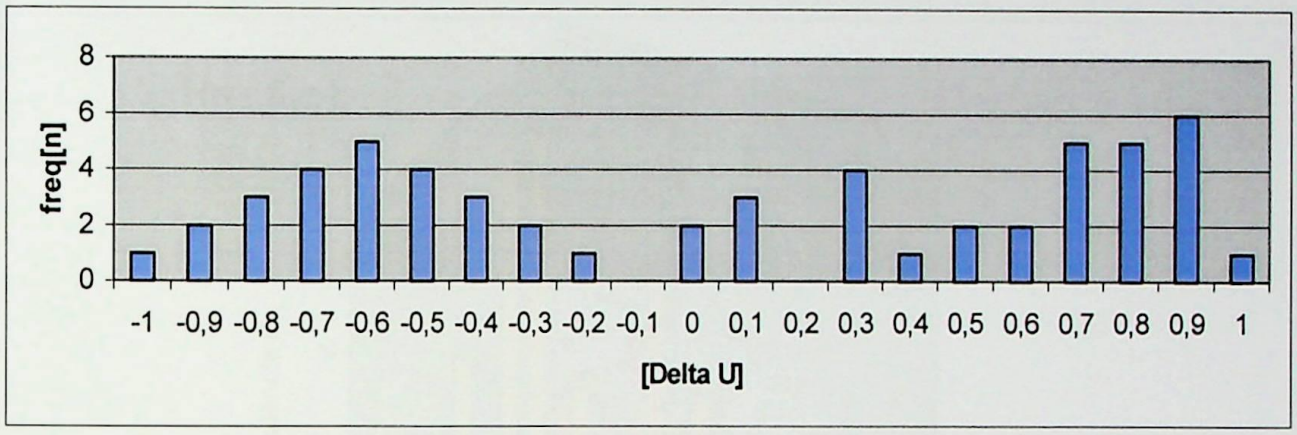


Figura 3.5 – Histograma de freqüência para ΔU

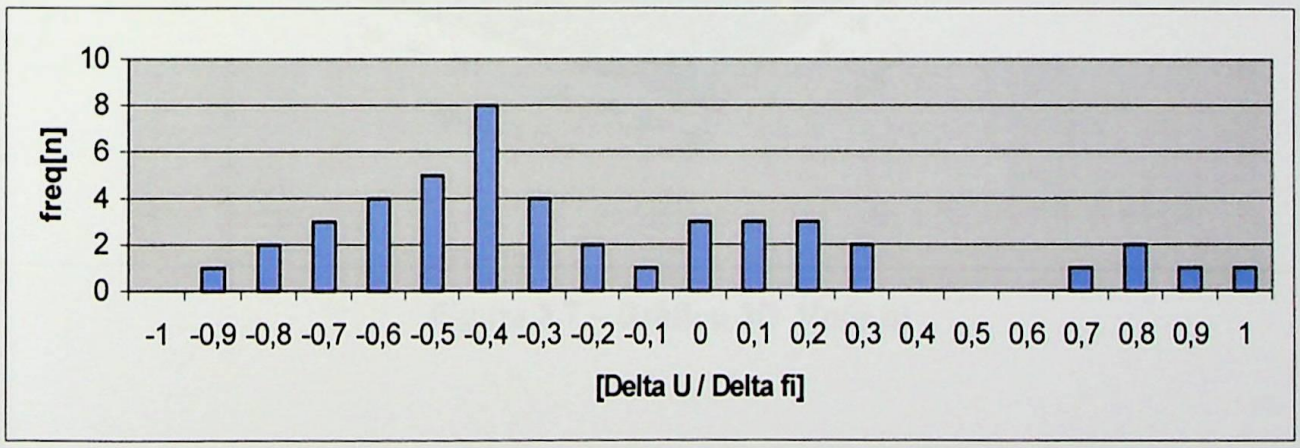


Figura 3.6 – Histograma de freqüência para $\Delta U/\Delta\varphi$

Estes dois vetores com 21 posições cada, formam o conjunto de 42 variáveis que servirão de entrada para treinamento da rede neural PMC utilizando operadores estatísticos no formato PRPS.

3.3 - Redes Neurais utilizando a grade de pixels do gráfico 3D φxqxN

Todas as informações do formato PRPD podem ser apresentadas em um único gráfico 3D, denominado de Hn(φ,q)(ver figura 3.7).

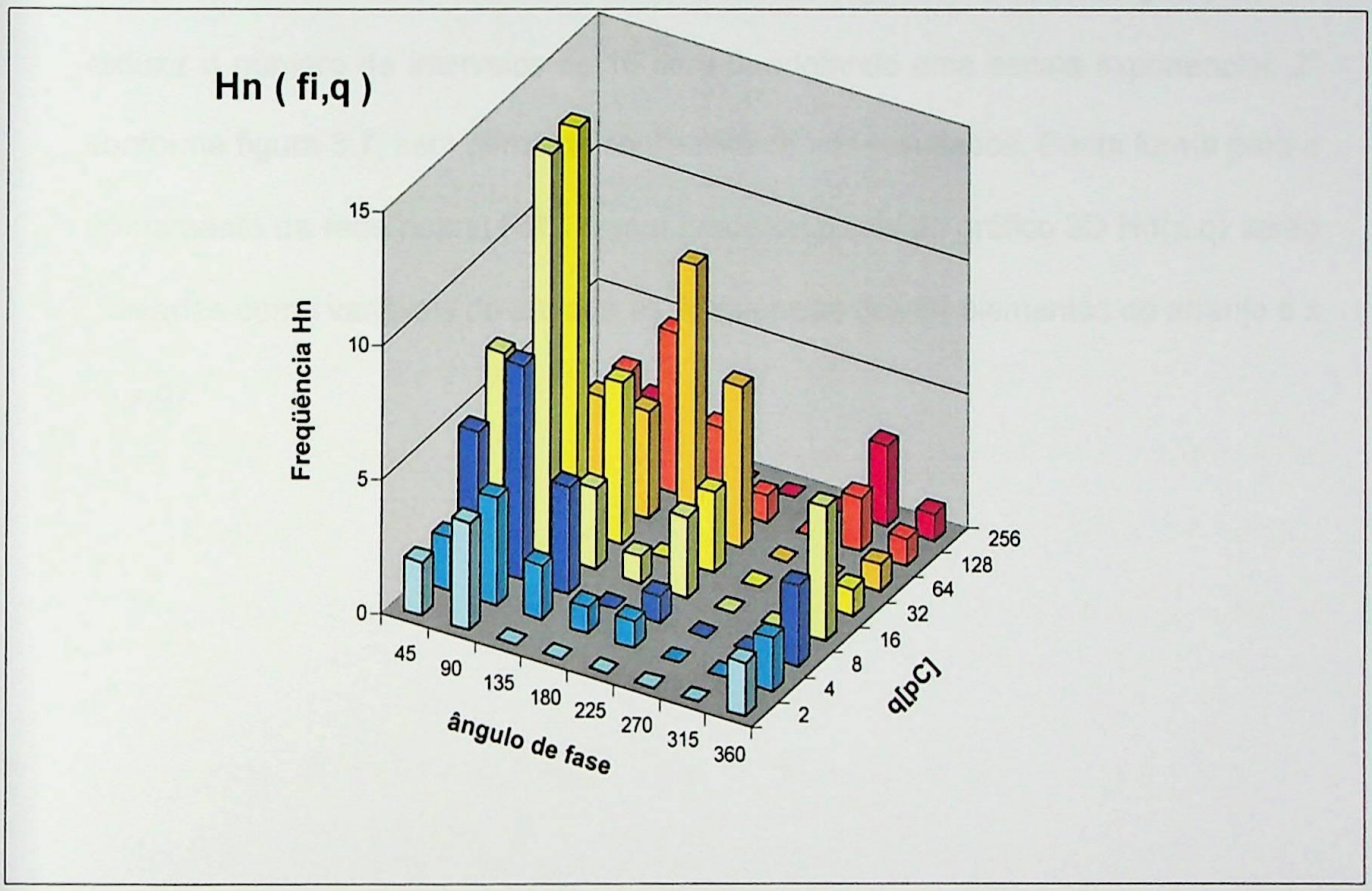


Figura 3.7 – Gráfico 3D Hn(φ,q)

[Gulski & Krivda, 93] descrevem a discretização do ângulo de fase φ, 0~360°, em 20 intervalos de 18°, e a magnitude da descarga em 16 intervalos, formando uma grade com 320 elementos.

[Satish & Zaengl, 94] propõem a redução de 20 para 8 intervalos (45°) para o ângulo de fase, mantendo 16 intervalos para a magnitude da descarga, havendo portanto a redução de 320 para 128 no número de elementos da grade.

Em uma análise prévia, com simulações nos dados disponíveis, verificou-se que uma redução para um valor inferior a 8 intervalos (45°) para o ângulo de fase compromete os resultados. Entretanto, para a magnitude da descarga, pode-se reduzir o número de intervalos de 16 para 8, adotando uma escala exponencial, 2^n conforme figura 3.7, sem perda de confiabilidade nos resultados. Desta forma para o treinamento da rede neural PMC com a grade de pixels do gráfico 3D Hn(φ,q) serão utilizadas como variáveis de entrada as freqüências dos 64 elementos do arranjo 8 x 8 (φ,**q**).

4 – RESULTADOS

Neste capítulo serão apresentados os resultados da aplicação das técnicas selecionadas e descritas em 3.1, 3.2 e 3.3, em sua forma original, assim como os refinamentos introduzidos, buscando o melhor desempenho quer através de alteração na forma de processamento dos arquivos de medições para obtenção das variáveis de entrada para a Rede Neural, quer de alteração na topologia da Rede Neural.

Com objetivo de identificar uma eventual dificuldade da rede neural para discernir sobre algum tipo específico de defeito entre os sete apresentados em 2.1, para cada uma das técnicas propostas foram treinadas 07 redes neurais, uma para classificar cada tipo de defeito. Cada rede neural foi configurada com dois neurônios de saída (codificação 1 de N), sendo as saídas esperadas 1 e 0 para verdadeiro ou 0 e 1 para falso, onde verdadeiro significa que o defeito apresentado foi classificado pela rede neural como sendo de sua classe e falso como não sendo de sua classe específica.

Antes da aplicação das técnicas, o conjunto de dados disponíveis, 420 arquivos(60 de cada um dos 07 tipos a serem classificados), foi permutado aleatoriamente dentro de cada classe e particionado em 03 conjuntos sendo:

60% para o conjunto de treinamento;

20% para o conjunto de validação;

20% para o conjunto de teste.

Desta partição foram extraídos os conjuntos respectivamente de treinamento, validação e teste para as sete redes neurais de modo a gerar conjuntos balanceados de dados, isto é 50% de “verdadeiros”(arquivo de medição da classe da rede), e

50% de "falsos", estes últimos com representantes das demais seis classes cabendo para cada rede conjuntos com a seguinte distribuição:

- ✓ Treinamento 72 arquivos sendo 36 de "verdadeiros" e 36 de "falsos"
- ✓ Validação 24 arquivos sendo 12 de "verdadeiros" e 12 de "falsos"
- ✓ Teste 24 arquivos sendo 12 de "verdadeiros" e 12 de "falsos"

[Demuth & Beale, 00] sugerem o uso função "Early Stopping" associada a um algoritmo de treinamento que não apresente uma convergência muito rápida como forma de otimizar a capacidade de generalização de uma rede neural, evitando sua especialização no conjunto de treinamento("overfitting").

Utilizando a "ToolBox" de redes neurais do MatLab 6.0 R12, fez-se uma análise e simulação prévia das 03 técnicas. Foram avaliadas alternativas utilizando os algoritmos de treinamento "traingd("gradient descent"), "traingdm"("Gradient descent with momentum") e "traingdx("Adaptative learning rate") com variações de uma e duas camadas intermediárias("hidden-layer"), assim como do número de neurônios de cada uma. Nesta simulação verificou-se ser o algoritmo de treinamento "traingdm" com uma camada intermediaria de 8 neurônios configurado com a função de validação "Early Stopping", suficiente para permitir a convergência durante o treinamento sem um tempo excessivo de processamento, e com boa capacidade de generalização.

De forma que a avaliação das 03 técnicas seja realizada com redes neurais com capacidade semelhante de discernimento será utilizado nas três aplicações a mesma topologia com uma camada intermediária de 8 neurônios.

Tem-se na figura 4.1 a seguir a topologia da rede neural utilizada no processamento do item 4.1 vista na forma de representação convencional, com os neurônios representados por círculos e suas conexões por segmentos de reta.

Na figura 4.2 tem-se a mesma rede vista através da representação gráfica da interface "nntool" da "ToolBox" de redes neurais do MatLab. Observa-se a representação das 15 variáveis de entrada, dos 8 neurônios da camada intermediária e dos 02 neurônios de saída na forma vetorial, com a indicação também gráfica da função de transferência utilizada, tangente hiperbólica sigmoide na camada intermediária e log-sigmoide na saída. Os respectivos conjuntos de pesos e bias a serem otimizados pelo algoritmo de treinamento estão assinalados na forma das matrizes "W" e "b".

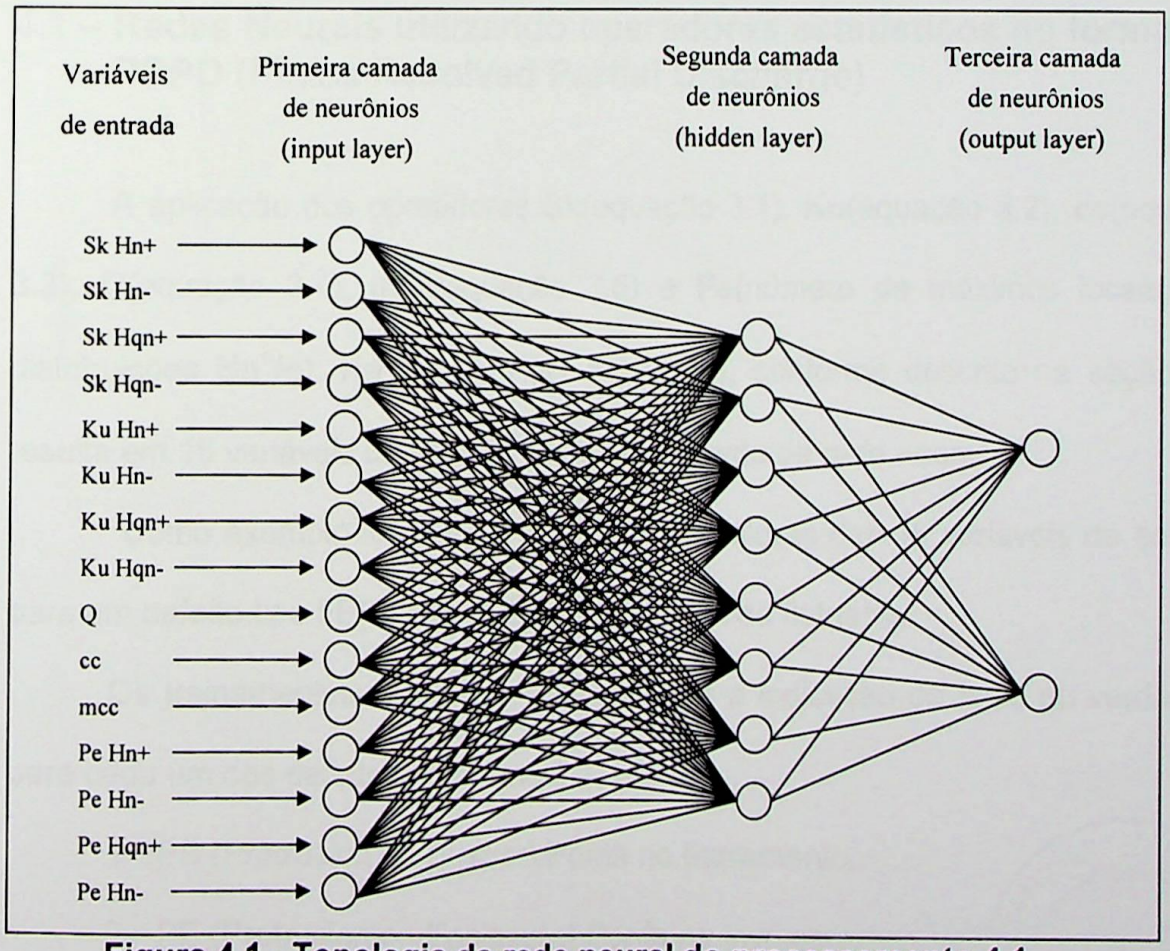


Figura 4.1 - Topologia da rede neural do processamento 4.1

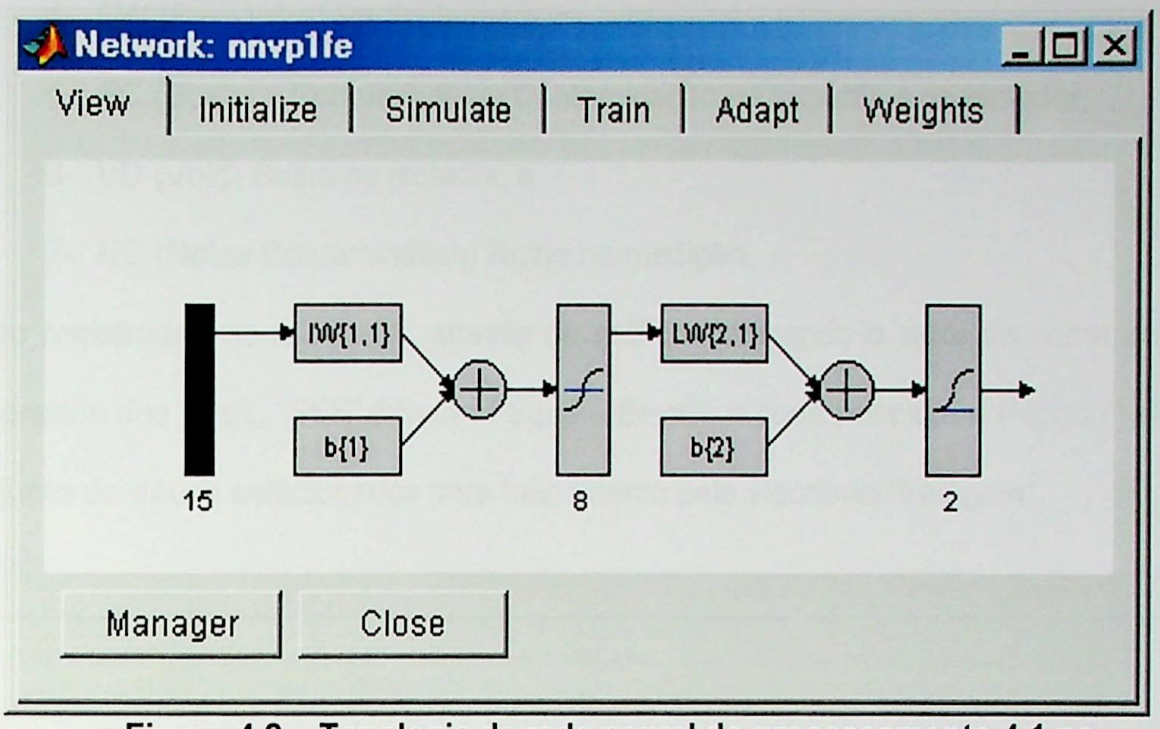


Figura 4.2 – Topologia da rede neural do processamento 4.1 na representação gráfica da "nntool" do MatLab

4.1 – Redes Neurais utilizando operadores estatísticos no formato PRPD (Phase Resolved Partial Discharge)

A aplicação dos operadores **Sk**(equação 3.1), **Ku**(equação 3.2), **cc**(equação 3.3), **Q**(equação 3.4), **mcc**(equação 3.5) e **Pe**(número de máximos locais) nas distribuições $\mathbf{Hn^{+}(\varphi)}$, $\mathbf{Hn^{-}(\varphi)}$, $\mathbf{Hqn^{+}(\varphi)}$ e $\mathbf{Hqn^{-}(\varphi)}$, conforme descrito na seção 3.1, resulta em 15 variáveis de entrada para treinamento da rede neural.

Como exemplo tem-se na figura 4.3 os valores das 15 variáveis de entrada para um defeito tipo FE("Floating Electrod"), eletrodo flutuante.

Os treinamentos das redes neurais, para a indicação de falso ou verdadeiro para cada um dos defeitos conforme 2.1, isto é,

1- PB (Protrusion on Busbar) Ponta no barramento,

2- PE (Protrusion on Enclosure) Ponta no invólucro,

3- FE (Floating Electrod) Eletrodo flutuante,

UNIVERSIDADE FEDERAL DE TAUBATÉ Biblioteca UNITAU UNITAU

4- FW (Free Wire) Partícula metálica livre,

5- SC (Surface Contamination) Contaminação na superfície do isolador,

6- VD (Void) Bolha no isolador, e

7- NC (Noise Contamination) Ruído na medição,

estão registrados no anexo 01, através de gráficos indicando o valor da soma dos quadrados dos erros, "SSE" ("Sum of Square Error"), a cada passagem ("epoch") do conjunto de dados selecionados para treinamento pelo algoritmo "traingdm".

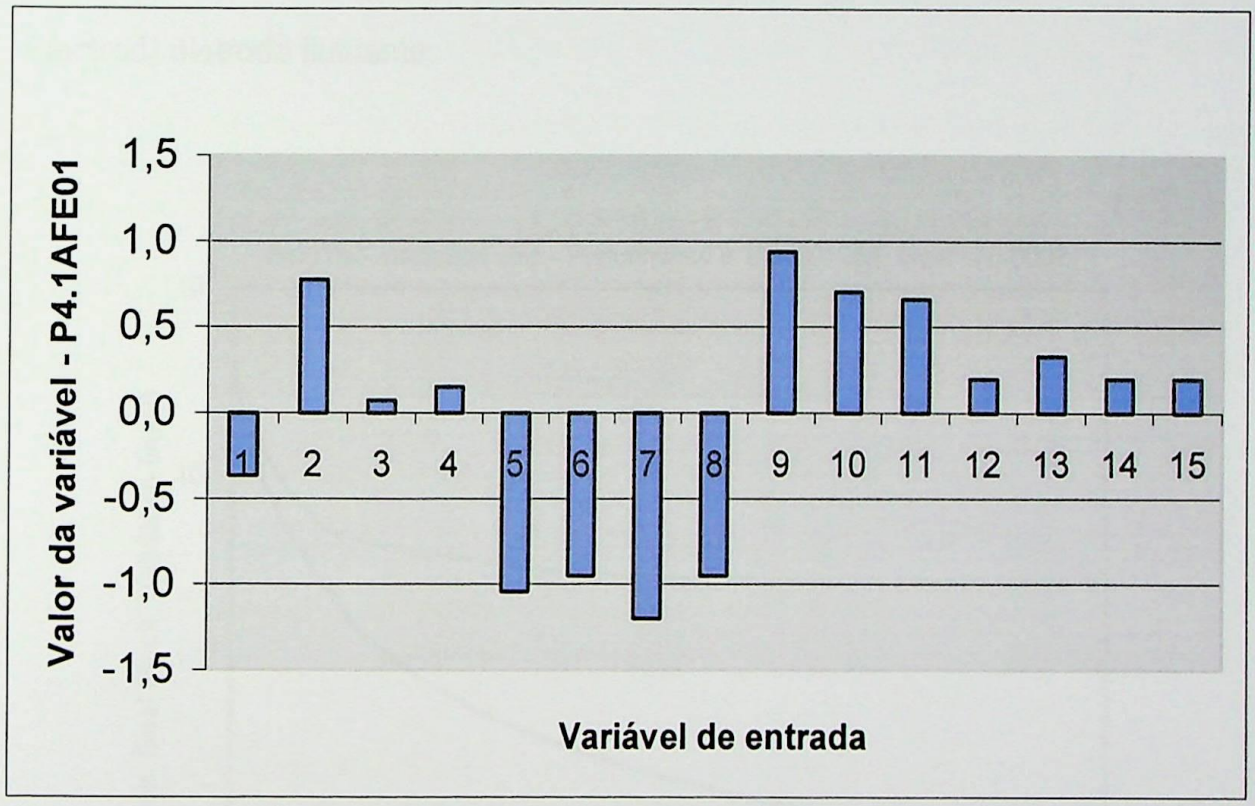


Figura 4.3 – Variáveis de entrada processamento 4.1 Arq.FE01

Além da "SSE" do conjunto de dados de treinamento, os gráficos também mostram a "SSE" do conjunto de dados de validação. Nos casos em que houve a interrupção do processo de treinamento devido a ativação da função "Early Stopping", que detecta o início de deterioração de desempenho no conjunto de

validação, aparece a notação "validation stop" no topo do gráfico juntamente com o valor da "SSE" no conjunto de treinamento no momento da interrupção.

Antes de se considerar como concluído o treinamento, para se evitar a coincidência de parada em um mínimo local, foi adotado o critério de reinicializar por cinco vezes o treinamento de cada rede neural, tomando-se como resultado aquele que obteve o melhor desempenho no conjunto de validação.

Na figura 4.4 observa-se a evolução dos valores da "SSE" nos conjuntos de treinamento (em azul) e de validação (em verde) para a rede neural FE (Floating Electrod) eletrodo flutuante.

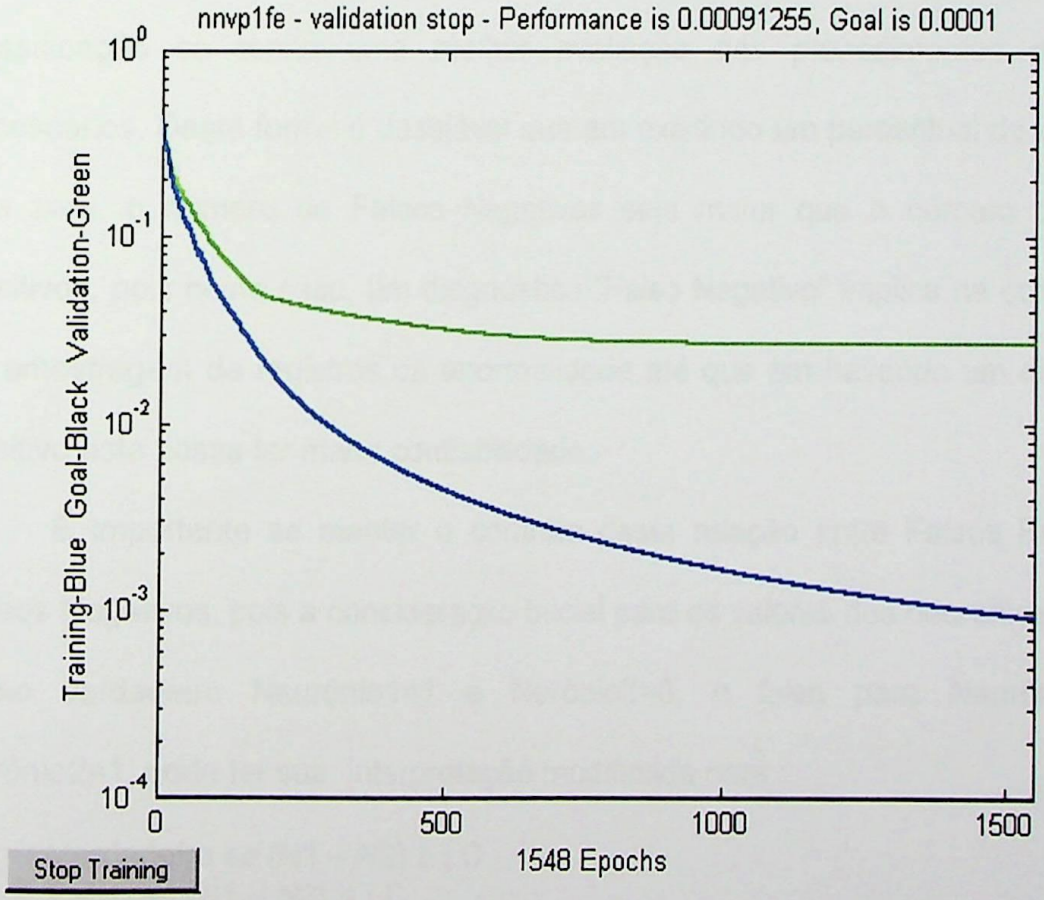


Figura 4.4 – Gráfico com valores da SSE para treinamento da rede neural relativa à identificação do defeito eletrodo flutuante

Após a conclusão da etapa de treinamento, as redes neurais tiveram seu desempenho avaliado sendo submetidas ao conjunto de arquivos separados especialmente para a finalidade de teste.

Além da avaliação do percentual de acertos, foi ainda discriminado o tipo de erro em falso positivo ou falso negativo, onde:

Falso Positivo significa que a rede neural retornou como verdadeiro quando o correto seria falso;

Falso Negativo significa que a rede neural retornou como falso quando o correto seria verdadeiro.

Para a aplicação específica da rede neural como ferramenta auxiliar no diagnóstico de registros de descargas parciais são passados para análise da rede neural apenas registros com evidência de anormalidade, para que após sua classificação se tenha uma melhor avaliação dos procedimentos de reparo necessários. Desta forma é desejável que em existindo um percentual de erro maior que zero, o número de Falsos Negativos seja maior que o número de Falsos Positivos, pois neste caso, um diagnóstico "Falso Negativo" implica na continuidade da amostragem de registros da anormalidade até que em havendo um diagnóstico Positivo este possa ter maior confiabilidade.

É importante se manter o controle desta relação entre Falsos Positivos e Falsos Negativos, pois a consideração inicial para os valores dos neurônios de saída como verdadeiro Neurônio1=1 e Nerônio2=0, e falso para Neurônio1=0 e Nerônio2=1, pode ter sua interpretação modificada para :

Verdadeiro se $(N1 - N2) \geq LC$
Falso se $(N1 - N2) < LC$

Onde N1= Valor do Neurônio1
N2 = Valor do Neurônio2
LC = Limite de confiança

Para o teste do conjunto de redes neurais tomou-se como valor LC=0,7.

Na tabela 4.1 encontram-se tabulados os resultados após a apresentação de 24 arquivos de teste para cada rede. Os arquivos foram apresentados em uma seqüência alternada de resultados verdadeiros e falsos.

Tabela 4.1- Desempenho da aplicação 4.1

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	1	1	91,7
FW	0	5	79,2
NC	1	3	83,3
PB	1	3	83,3
PE	2	4	75
SC	0	5	79,2
VD	0	3	87,5
Total	5	24	82,7

O desempenho apresentado, 82,7% de acerto, está abaixo do esperado para esta técnica, conforme relatado em [Kreuger *et al*, 93]. Uma análise do comportamento das variáveis de entrada obtidas pela aplicação dos operadores **Sk**(equação 3.1), **Ku**(equação 3.2) levou a uma proposta de refinamento descrita em 4.1.1 a seguir.

4.1.1 – Refinamento dos operadores Sk e Ku

Observa-se na figura 4.5 que os valores das variáveis 6 e 8, diferentemente das demais, não se mantêm na mesma faixa de valores conforme na figura 4.3. Os valores de Skewnees e Kurtosis para distribuições monomodais se mantêm no intervalo de –1 até +1 [Kreuger *et al*, 93], porém para distribuições multimodais estes limites não são válidos [Papoulis, 91] [Hahn & Shapiro, 94].

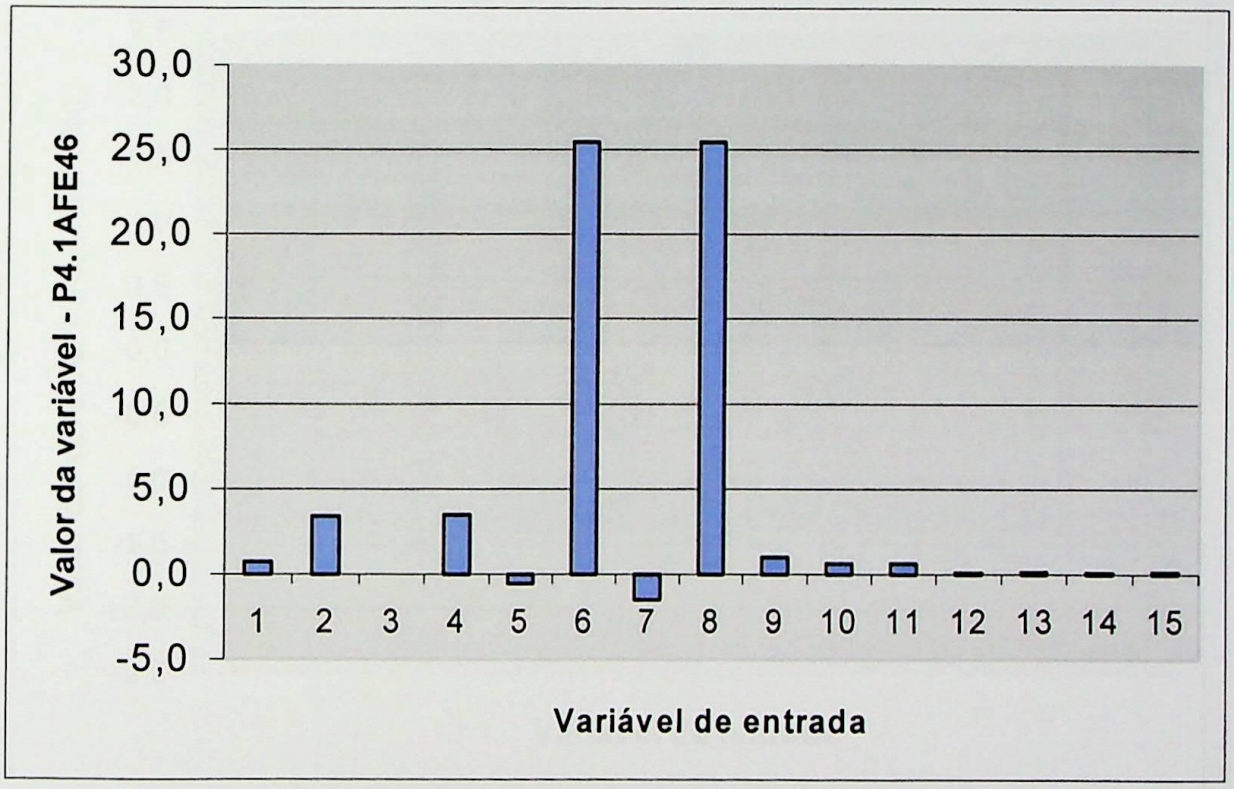


Figura 4.5 - Variáveis de entrada processamento 4.1- Arq.FE46

O equipamento de monitoramento utilizado faz aquisições em pequenos intervalos de tempo, de 1 a 6 segundos, não permitindo em alguns casos um delineamento uniforme da distribuição, o que ocorre nos exemplos de [Kreuger *et al*, 93] com aquisições durante 20 minutos.

Para reduzir o intervalo de valores das variáveis de entrada sem comprometer a resolução no intervalo de –1 até +1, onde os arquivos contém informações importantes para o treinamento da rede neural, foi implementado com bom resultado a compressão logarítmica para a faixa de valores fora do intervalo [-1, 1], adotando-se como novo valor de x (1+ log (x)) para x > 1, e (-1 -log (|x|)) para x < -1.

Na figura 4.6 tem-se o mesmo arquivo, FE46, já processado com o refinamento nas funções **Sk** e **Ku**.

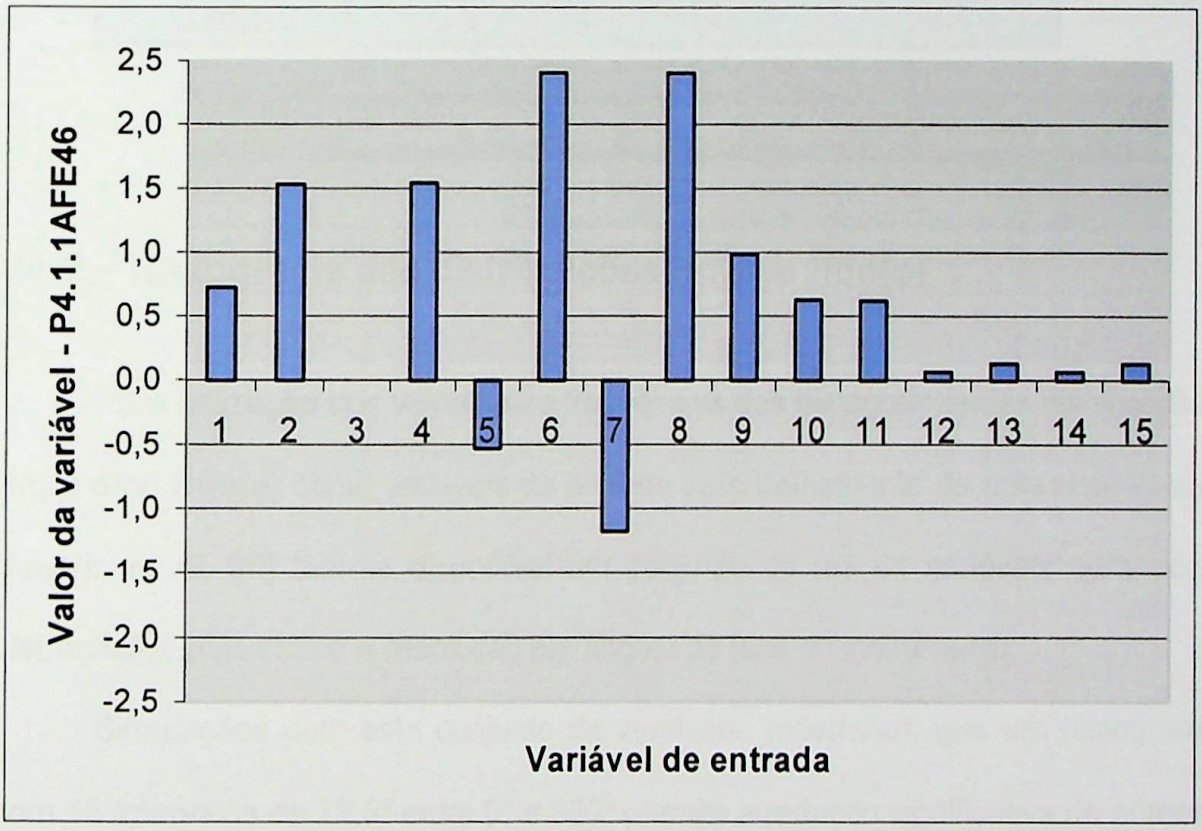


Figura 4.6 - Variáveis de entrada processamento 4.1.1- Arq.FE46

O desempenho melhorou de 82,7% para 88,1% conforme mostrado na tabela 4.2. Este desempenho ainda é um resultado tímido, desta forma a implementação de uma segunda alternativa usando as distribuições **Hn(φ)** e **Hqn(φ)** será descrita em 4.1.2.

Tabela 4.2 - Desempenho da aplicação 4.1.1

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	2	91,7
FW	0	5	79,2
NC	0	3	87,5
PB	1	1	91,7
PE	0	1	95,8
SC	0	5	79,2
VD	0	2	91,7
Total	1	19	88,1

4.1.2 – Histograma das distribuições Hn(φ) e Hqn(φ)

Para utilização dos valores das freqüências dos histogramas das distribuições **Hn(φ)** e/ou **Hqn(φ)** como variáveis de entrada para treinamento de uma rede neural [Amorin *et al*, 99] tem-se disponível um conjunto de até 64 variáveis para cada distribuição, pois esta é a resolução em ângulo de fase do instrumento.

Simulações com este conjunto de variáveis mostraram que um histograma com 16 intervalos de 22,5° entre 0° e 360° permite a redução significativa do número de variáveis de entrada, reduzindo o tempo de processamento sem comprometer a capacidade de classificação da rede neural.

Na figura 4.7 tem-se o conjunto de variáveis para o arquivo FE01, sendo as variáveis de 1 a 16 relativas ao histograma de **Hn(φ)** e as variáveis de 17 a 32 relativas ao histograma de **Hqn(φ)**. Os valores das freqüências para cada intervalo foram normalizadas em função do maior valor, ficando assim no intervalo de 0 a 1. O

desempenho conseguido, 97,0%, tabela 4.3, mostra uma melhora significativa em relação a 82,7% do processamento 4.1 e 88,1% do processamento 4.1.1.

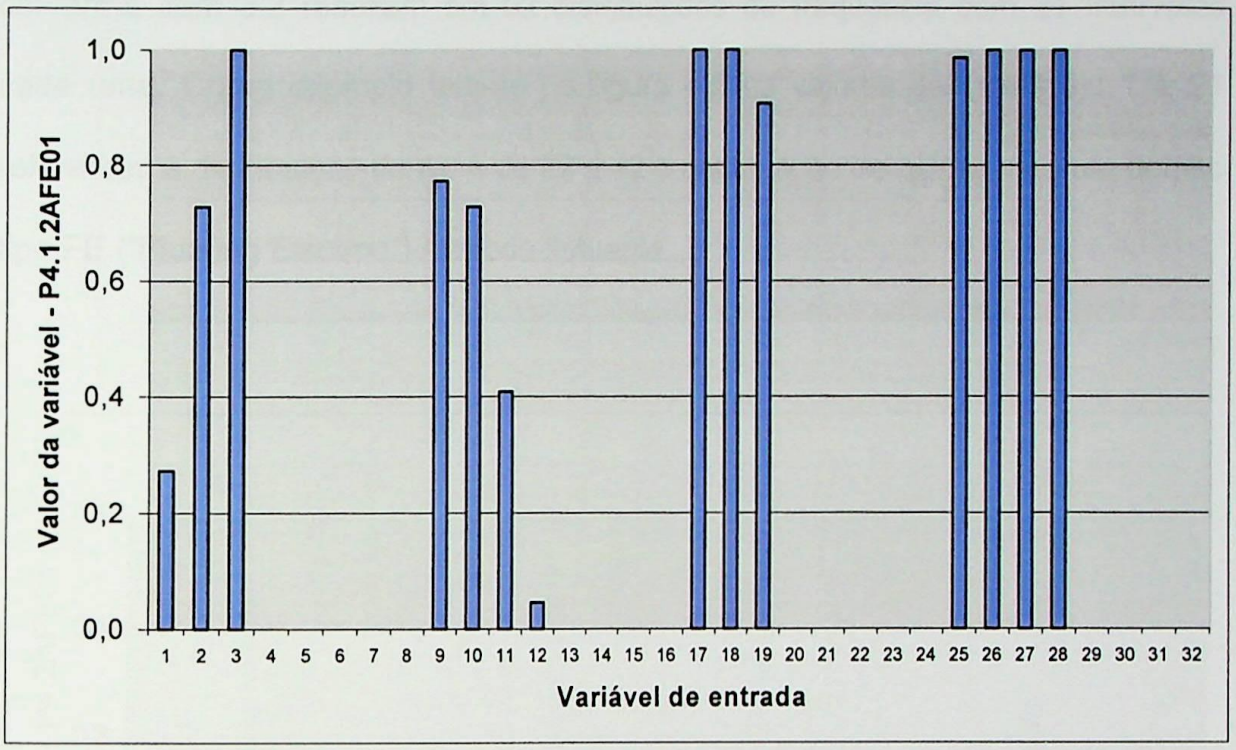


Figura 4.7 - Variáveis de entrada processamento 4.1.2- Arq.FE01

Tabela 4.3 - Desempenho da aplicação 4.1.2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	1	2	87,5
NC	0	2	91,7
PB	0	0	100,0
PE	0	0	100,0
SC	0	0	100,0
VD	0	0	100,0
Total	1	4	97,0

4.2 – Redes Neurais utilizando operadores estatísticos no formato PRPS (Phase Resolved Pulse Sequence)

A aplicação dos operadores **ΔU** (equação 3.6) e **ΔU/Δφ** (equação 3.7) conforme item 3.2 resultam em 02 distribuições de freqüência com 21 intervalos cada uma. Como exemplo tem-se na figura 4.8 os valores das variáveis 1 a 21 referentes à distribuição de **ΔU** e de 22 a 42 à distribuição de **ΔU/Δφ** para um defeito tipo FE ("Floating Electrod") eletrodo flutuante.

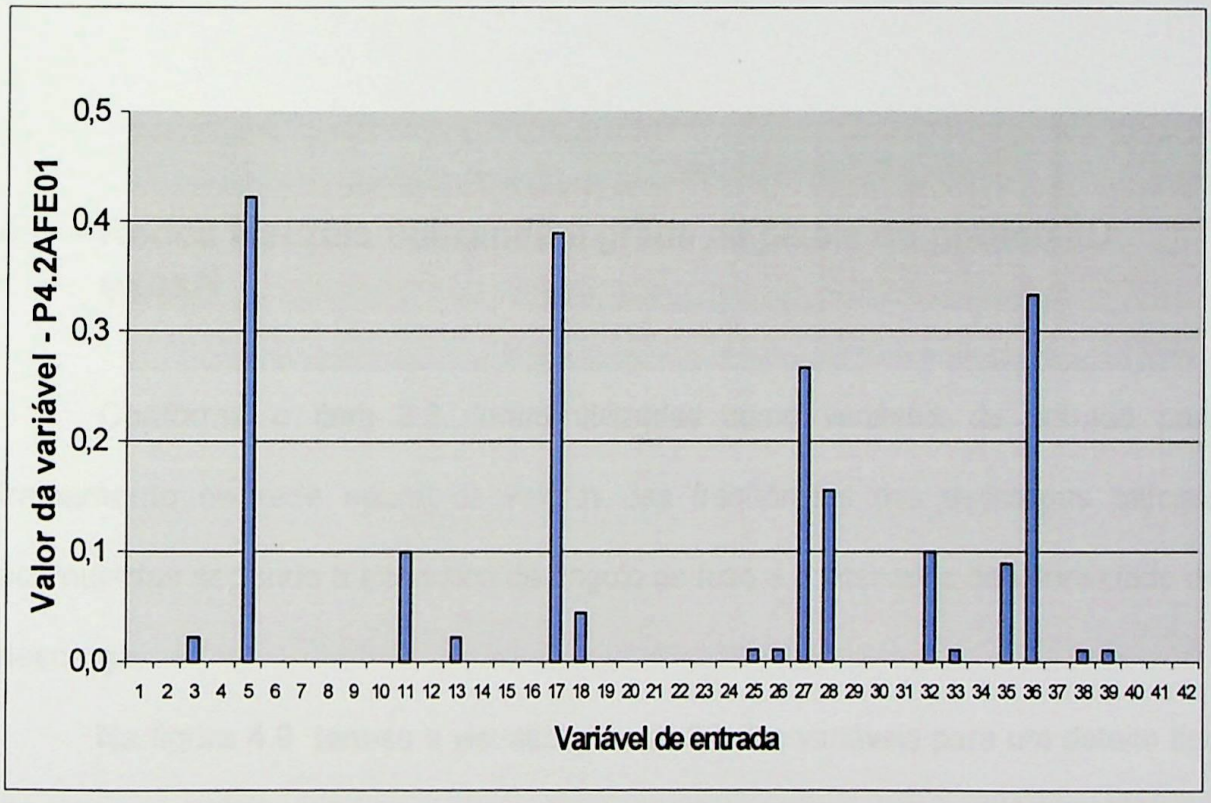


Figura 4.8 - Variáveis de entrada processamento 4.2- Arq.FE01

Esta aplicação apresentou um desempenho de 98,8%, conforme tabela 4.4 a seguir. Para esta técnica não foi proposto nenhum refinamento uma vez que o desempenho apresentado é considerado satisfatório.

Tabela 4.4 - Desempenho da aplicação 4.2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	0	0	100,0
NC	0	0	100,0
PB	0	1	95,8
PE	0	0	100,0
SC	0	1	95,8
VD	0	0	100,0
Total	0	2	98,8

4.3 – Redes Neurais utilizando a grade de pixels do gráfico 3D φxqxN

Conforme o item 3.3, foram utilizadas como variáveis de entrada para treinamento da rede neural os valores das freqüências das descargas parciais acumuladas segundo 8 intervalos de ângulo de fase e 8 intervalos de intensidade da descarga.

Na figura 4.9 tem-se a visualização em 3D das variáveis para um defeito tipo FE ("Floating Electrod") eletrodo flutuante.

O desempenho apresentado, 98,8% conforme tabela 4.5, da mesma forma que em 4.2 é considerado satisfatório, porém o número de variáveis de entrada, 64, pode ser considerado excessivo, o que acarreta um maior tempo de processamento durante o treinamento da rede neural e uma possível diminuição na robustez da capacidade de generalização dos classificadores.

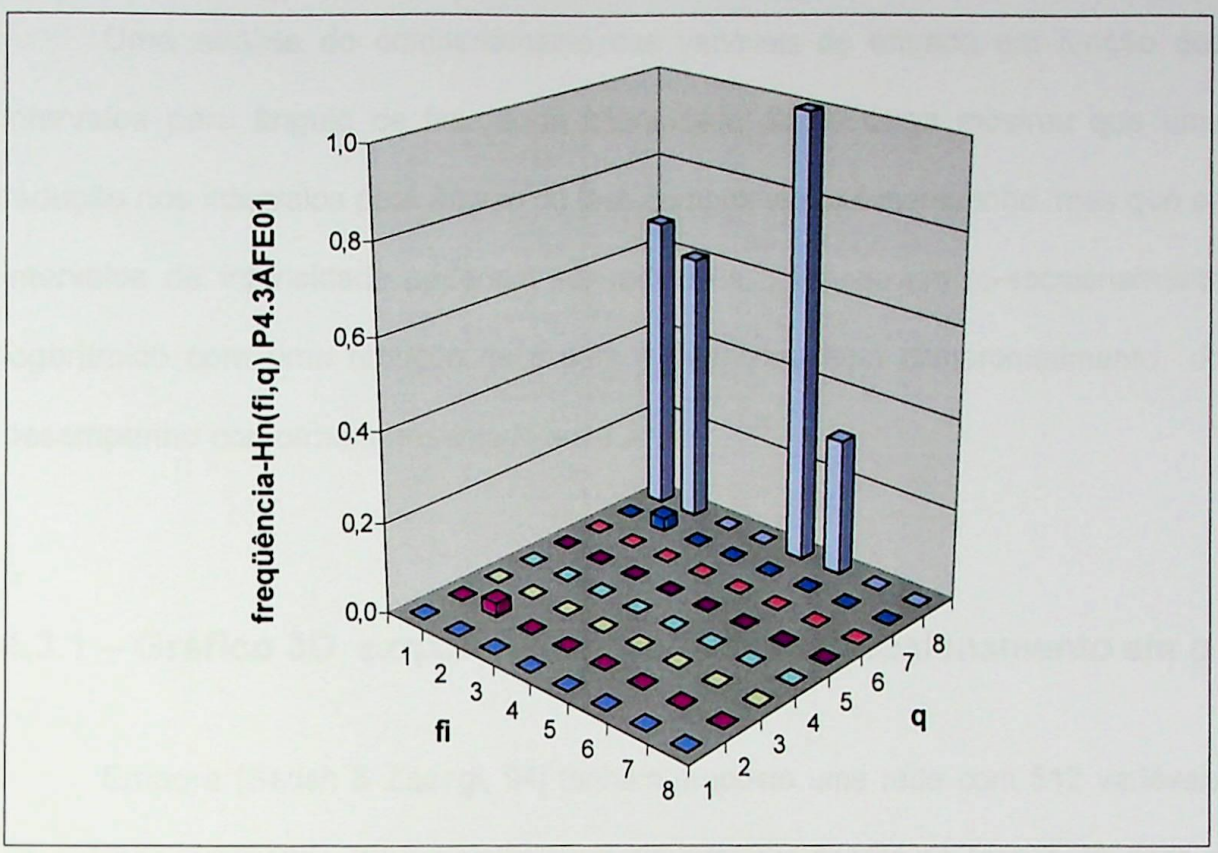


Figura 4.9 - Variáveis de entrada processamento 4.3- Arq.FE01

Tabela 4.5 - Desempenho da aplicação 4.3

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	0	0	100,0
NC	0	1	95,8
PB	0	0	100,0
PE	0	0	100,0
SC	0	1	95,8
VD	0	0	100,0
Total	0	2	98,8

Uma análise do comportamento das variáveis de entrada em função dos intervalos para ângulo de fase e da intensidade da descarga mostrou que uma redução nos intervalos para ângulo de fase compromete o desempenho, mas que os intervalos de intensidade poderiam ser reduzidos utilizando um re-escalonamento logarítmico com uma redução de 8 para 4 intervalos, sem comprometimento do desempenho conforme apresentado em 4.3.1.

4.3.1 – Gráfico 3D φxqxN–refinamento com re-escalonamento em q

Embora [Satish & Zaengl, 94] tenham proposto uma rede com 512 variáveis de entrada, utilizando 32 intervalos para discretizar o ângulo de fase e 16 para a intensidade de descarga, este número é excessivo se for considerado que o objetivo de classificar os 7 tipos de defeitos propostos em 2.1 tem sido atingido de forma satisfatória com menos variáveis.

Mantendo uma escala linear na divisão dos intervalos de ângulo de fase e uma escala logarítmica nos intervalos de intensidade da descarga, a menor divisão que não comprometeu o desempenho foi a mostrada em 4.3, com 64 variáveis.

O refinamento aqui proposto que reduziu de 8 para 4 os intervalos da intensidade de descarga e consequentemente de 64 para 32 as variáveis de entrada, foi a aplicação de um re-escalonamento nos intervalos logarítmicos de intensidade da descarga. Com esta redução, a visualização em 3D das 32 variáveis ficou conforme figura 4.10. Mesmo com a redução do número de variáveis não houve comprometimento do desempenho, obtendo-se uma melhora na taxa

classificação de 98,8% para 99,4% conforme tabela 4.6. Este foi o melhor desempenho conseguido entre as técnicas até aqui apresentadas.

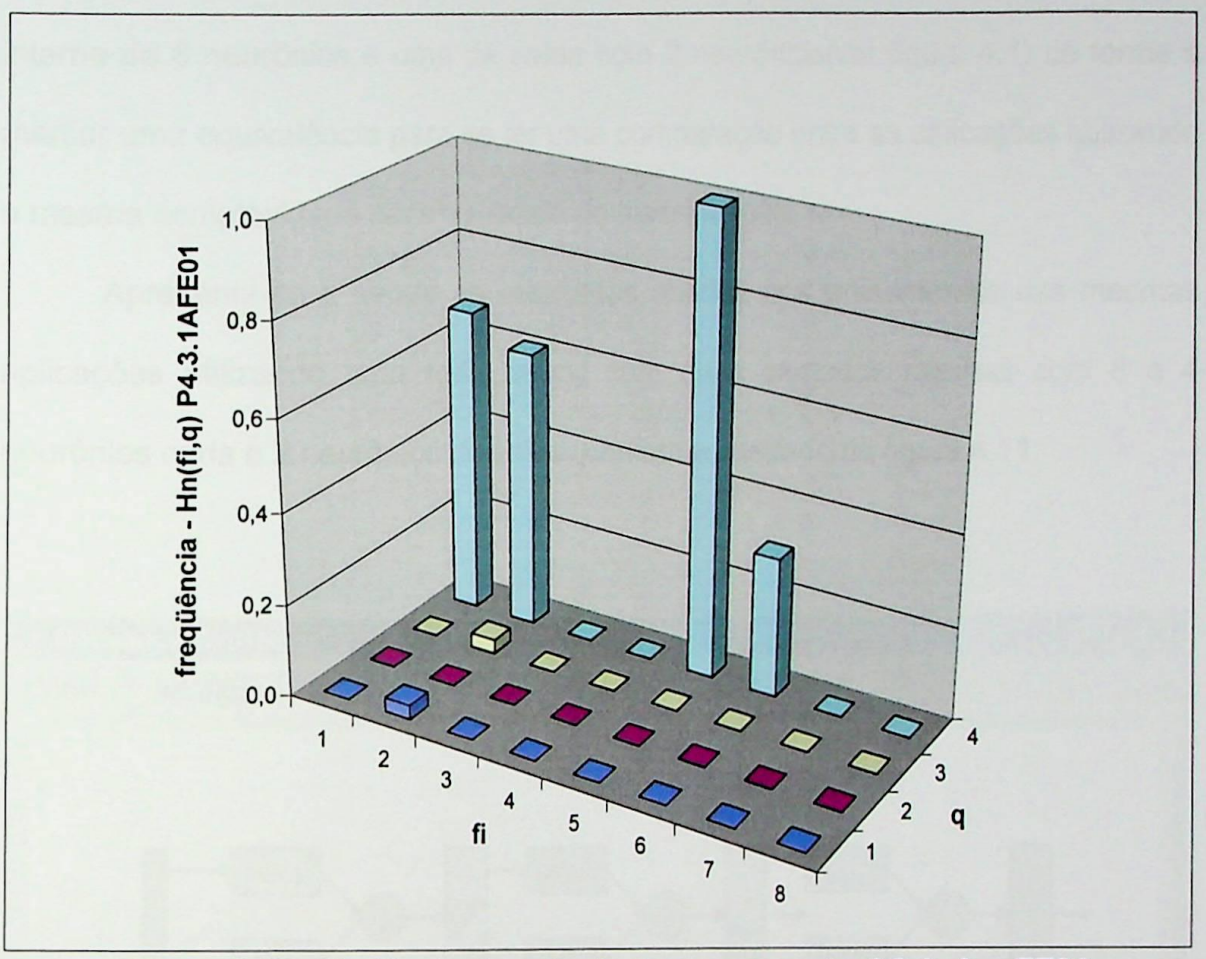


Figura 4.10 - Variáveis de entrada processamento 4.3.1- Arq.FE01

Tabela 4.6 - Desempenho da aplicação 4.3.1

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	0	0	100,0
NC	0	1	95,8
PB	0	0	100,0
PE	0	0	100,0
SC	0	0	100,0
VD	0	0	100,0
Total	0	1	99,4

4.4 – Utilização de uma topologia com 2 camadas internas

Nos itens 4.1 a 4.3 foi utilizada sempre a mesma topologia com uma camada interna de 8 neurônios e uma de saída com 2 neurônios(ver figura 4.1) de forma a manter uma equivalência para se ter uma comparação entre as aplicações utilizando a mesma complexidade para o modelo de classificação.

Apresenta-se a seguir os resultados obtidos nos treinamentos das mesmas aplicações utilizando uma rede neural com duas camadas internas com 8 e 4 neurônios cada e 2 neurônios de saída, conforme ilustrado na figura 4.11.

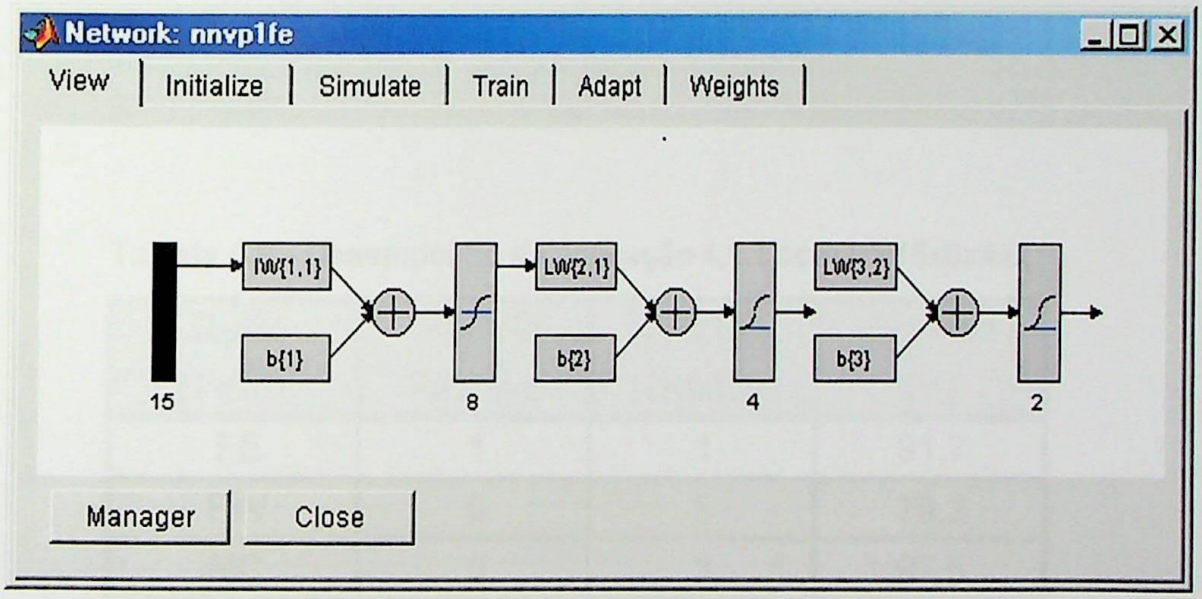


Figura 4.11 - Topologia da rede neural do processamento 4.4

A aplicação 4.1 teve um incremento na taxa de classificação de 82,7% para 86,9%, conforme tabela 4.7. A aplicação 4.1.1 teve um incremento em seu desempenho de 88,1% para 88,7%, conforme tabela 4.8.

Tabela 4.7 - Desempenho da aplicação 4.1 com RN15x8x4x2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	1	95,8
FW	0	4	83,3
NC	1	2	87,5
PB	1	0	95,8
PE	1	2	87,5
SC	0	4	83,3
VD	1	2	87,5
Total	4	15	88,7

Tabela 4.8 - Desempenho da aplicação 4.1.1 com RN15x8x4x2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	1	1	91,7
FW	0	5	79,2
NC	0	3	87,5
PB	0	2	91,7
PE	3	1	83,3
SC	0	5	79,2
VD	0	1	95,8
Total	4	18	86,9

A aplicação 4.1.2 teve uma melhora em seu desempenho de 97,0% para 98,2%, conforme tabela 4.9. Já a aplicação 4.2 melhorou de 98,8% para 99,4%, conforme tabela 4.10.

Tabela 4.9 - Desempenho da aplicação 4.1.2 com RN32x8x4x2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	1	1	91,7
NC	0	1	95,8
PB	0	0	100,0
PE	0	0	100,0
SC	0	0	100,0
VD	0	0	100,0
Total	1	2	98,2

Tabela 4.10 - Desempenho da aplicação 4.2 com RN42x8x4x2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	0	0	100,0
NC	0	0	100,0
PB	0	1	95,8
PE	0	0	100,0
SC	0	0	100,0
VD	0	0	100,0
Total	0	1	99,4

A aplicação 4.3 não mostrou progresso mantendo 98,8% conforme tabela 4.11, e finalmente a aplicação 4.3.1 teve um incremento em sua taxa de classificação de 99,4% para 100,0%, conforme tabela 4.12.

Tabela 4.11 - Desempenho da aplicação 4.3 com RN64x8x4x2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	0	0	100,0
NC	0	0	100,0
PB	0	0	100,0
PE	0	0	100,0
SC	1	1	91,7
VD	0	0	100,0
Total	1	1	98,8

Tabela 4.12 - Desempenho da aplicação 4.3.1 com RN32x8x4x2

Rede Neural	FALSO Positivo	FALSO Negativo	Acertos [%]
FE	0	0	100,0
FW	0	0	100,0
NC	0	0	100,0
PB	0	0	100,0
PE	0	0	100,0
SC	0	0	100,0
VD	0	0	100,0
Total	0	0	100,0

4.5 - Análise dos resultados

A comparação do desempenho na classificação dos defeitos obtida por cada uma das técnicas pode ser visualizada na tabela 4.13 a seguir.

Os pré-processamentos propostos em 4.1(**82,7% / 86,9%**) e 4.1.1(**88,1% / 88,7%**), com 15 operadores estatísticos no formato PRPD, mostraram-se inadequados para uma aplicação direta nas informações disponibilizadas pelo instrumento da DMS. Porém, em 4.1.2 (**97,0% / 98,2%**), embora ainda inferior aos demais, os resultados encontram-se em um patamar aceitável para a utilização como parte de um sistema real.

Pelos resultados obtidos em 4.2 (**98,8% / 99,4%**), 4.3 (**98,8%**) e 4.3.1 (**99,4% / 100,0%**), demonstra-se que estas técnicas são plenamente compatíveis com a forma de medição indireta do equipamento da DMS, permitindo a sua aplicação em um sistema de classificação altamente confiável.

Tabela 4.13 – Comparação de desempenho na taxa de classificação

Pré-processamento	Rede Neural	Topologia					
		inp x 8 x 2			inp x 8 x 4 x 2		
		FALSO Positivo	FALSO Negativo	Acertos [%]	FALSO Positivo	FALSO Negativo	Acertos [%]
4.1 PRPD	FE	1	1	91,7	1	1	91,7
	FW	0	5	79,2	0	5	79,2
	NC	1	3	83,3	0	3	87,5
	PB	1	3	83,3	0	2	91,7
	PE	2	4	75,0	3	1	83,3
	SC	0	5	79,2	0	5	79,2
	VD	0	3	87,5	0	1	95,8
	Total 4.1	**5**	**24**	**82,7**	**4**	**18**	**86,9**
4.1.1 PRPD (ref. Sk e Ku)	FE	0	2	91,7	0	1	95,8
	FW	0	5	79,2	0	4	83,3
	NC	0	3	87,5	1	2	87,5
	PB	1	1	91,7	1	0	95,8
	PE	0	1	95,8	1	2	87,5
	SC	0	5	79,2	0	4	83,3
	VD	0	2	91,7	1	2	87,5
	Total 4.1.1	**1**	**19**	**88,1**	**4**	**15**	**88,7**
4.1.2 PRPD (Hist. Hn+Hqn)	FE	0	0	100,0	0	0	100,0
	FW	1	2	87,5	1	1	91,7
	NC	0	2	91,7	0	1	95,8
	PB	0	0	100,0	0	0	100,0
	PE	0	0	100,0	0	0	100,0
	SC	0	0	100,0	0	0	100,0
	VD	0	0	100,0	0	0	100,0
	Total 4.1.2	**1**	**4**	**97,0**	**1**	**2**	**98,2**
4.2 PRPS	FE	0	0	100,0	0	0	100,0
	FW	0	0	100,0	0	0	100,0
	NC	0	0	100,0	0	0	100,0
	PB	0	1	95,8	0	1	95,8
	PE	0	0	100,0	0	0	100,0
	SC	0	1	95,8	0	0	100,0
	VD	0	0	100,0	0	0	100,0
	Total 4.2	**0**	**2**	**98,8**	**0**	**1**	**99,4**
4.3 3D (H(fi,q) 8x8)	FE	0	0	100,0	0	0	100,0
	FW	0	0	100,0	0	0	100,0
	NC	0	1	95,8	0	0	100,0
	PB	0	0	100,0	0	0	100,0
	PE	0	0	100,0	0	0	100,0
	SC	0	1	95,8	1	1	91,7
	VD	0	0	100,0	0	0	100,0
	Total 4.3	**0**	**2**	**98,8**	**1**	**1**	**98,8**
4.3.1 3D (H(fi,q) 8x4)	FE	0	0	100,0	0	0	100,0
	FW	0	0	100,0	0	0	100,0
	NC	0	1	95,8	0	0	100,0
	PB	0	0	100,0	0	0	100,0
	PE	0	0	100,0	0	0	100,0
	SC	0	0	100,0	0	0	100,0
	VD	0	0	100,0	0	0	100,0
	Total 4.3.1	**0**	**1**	**99,4**	**0**	**0**	**100,0**

UNIVERSIDADE FEDER

5 – CONCLUSÃO

Neste capítulo será apresentada a conclusão sobre as aplicações implementadas, os resultados obtidos e também abordados aspectos relacionados a implementação futura de uma ferramenta de suporte para engenharia.

Pelas taxas de classificação conseguidas, atingindo o patamar de 97% a 100% de acerto na classificação, tem-se que o objetivo proposto de ***aplicação e avaliação do desempenho*** de Redes Neurais para classificar diversos tipos de defeito em equipamentos isolados em SF_6, a partir de resultados de medição de um sistema de monitoramento em UHF foi alcançado com sucesso.

Conforme proposto em 2.1, temos os seguintes aspectos para serem avaliados nos conjuntos de técnicas utilizadas nas fases de pré-processamento dos arquivos de medição e treinamento das redes neurais,

- ✓ *Confiabilidade*
- ✓ *Tempo de computação*
- ✓ *Simplicidade da aplicação*

O percentual de acertos nos indica a confiabilidade que pode ser atribuída a cada um dos conjuntos. Conforme análise em 4.5, exceto as técnicas 4.1 e 4.1.1(**PRPD** com operadores estatísticos), as demais(distribuições **Hn(φ)+Hqn(φ)**, **PRPS** e **grade 3D**) apresentam-se como candidatas para uso em ferramentas de classificação para uso em um sistema real.

No conjunto de dados disponível, cabe ressaltar o excelente desempenho (**99,4% / 100,0%**) da técnica 4.3.1, Redes Neurais PMC utilizando como variáveis de

entrada a grade de pixels do gráfico **3D φxqxN**, **Hn(φxq)**.

Quanto aos critérios de tempo de computação e simplicidade da aplicação, não existiu diferença significativa entre as aplicações na fase de pré-processamento, ficando alguma diferença apenas na fase de treinamento das redes neurais. Estas diferenças talvez tivessem maior significado (horas), num passado recente utilizando processadores com "clock" na faixa de dezenas de megahertz, não chegando a ser relevante (minutos) quando executadas em um processador com "clock" de mais de 1 gigahertz.

✓ Fica como constatação positiva do trabalho a compatibilidade das técnicas sugeridas com os arquivos de medição indireta por UHF do equipamento de campo, não cabendo no momento excluir a de menor desempenho ou eleger como prioritária a que melhor se apresentou.

✓ Como sugestão de trabalho futuro, fica o desenvolvimento de uma ferramenta que utilize simultaneamente, de forma paralela, várias das técnicas sugeridas, informando ao usuário a classificação obtida de cada uma, e ainda um índice de confiança para cada classificação, por exemplo o valor (N1 – N2). Esta ferramenta poderá em um primeiro estágio ser utilizada de forma independente do sistema de monitoramento, e posteriormente ser integrada ao mesmo.

✓ Utilização da combinação de classificadores e desenvolvimento de topologias específicas para a identificação de cada tipo de defeito.

✓ Como as demais aplicações de redes neurais, a ferramenta deverá permitir a sua adaptação para novos arquivos de treinamento, que poderão ter origem nos equipamentos em operação ou ser objeto de trabalho desenvolvido em conjunto com centros de pesquisa.

6 – REFERÊNCIAS

[Amorin *et al*, 99] – Amorin, Helio P., Vellasco, Marley Maria, Lima, Antônio Guilherme G., Levy, Alain François S. – "Recognition of partial discharge of high voltage equipment using neural network", ISAP'99, paper 0217, Rio de Janeiro, Abril 1999.

[Bishop, 98] – Bishop, Christopher M. – "Neural Networks for Pattern Recognition" – Clarendon Press Oxford, 3° Edição 1998

[Borsi, 00] – Borsi, H. - "A PD Measuring and Evaluation System Based on Digital Signal Processing" , IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7 No. 1, pp. 21-29, Fevereiro 2000.

[Demuth & Beale, 00] – Demuth, H., Beale, M. – "Neural Network Toolbox User's Guide" – The Mathworks, Inc, 6° Edição, Setembro 2000.

[ESAFLON-AUSIMONT, 99] – Catálogo com informações técnicas sobre o gás SF_6, Esaflon, do fabricante italiano Ausimont S.p.A, 1999.

[FES, 85] – Catálogo do fabricante de instrumentos, FES International LTD – Canada, 1985.

[Gulski & Krivda, 93] – Gulski, E., Krivda, A. – "Neural Networks as a Tool for Recognition of Partial Discharges", IEEE Transactions on Electrical Insulation, Vol. 28 No. 6, pp. 984-1001, Dezembro 1993.

[Hahn & Shapiro, 94] – Hahn, Gerald J., Shapiro, Samuel S. – "Statistical Models in Ingineering", John Willey & Sons, 1° Edição 1994.

[Hampton, 01] – Hampton, B. – "DMS - Partial Discharge Monitoring System", Curso/treinamento ministrado durante comissionamento do Sistema de Monitoramento da Usina de Ita-Gerasul, Agosto 2001.

[Hoof & Patsh, 97] – Hoof, M., Patsch, R. – "Detection of Multiple Discharge Sites Using Pulse/Pulse Corrrelation", I.C.D.I., pp. 213-216, Budapest, Hungria, 1997.

[Huecker *et al*, 98] – Huecher, T., Boeck, W., Blackburn, T., Girodet, A., Graf, E., Gulski, E., Hikita, M., Koltunowicz, W., Kranz, H. G., Lundgaard, L., Maulat, C., Neumann, C., Pietsch, R., Petit, A. – "CIGRE data format for GIS partial discharge software applications" , Revista Electra, No. 177, pp. 87-93, Abril 1998.

[IEC60.270, 98] – International Electrotechnical Commission. – "High-Voltage Test Techniques – Partial Discharge Measurements" , 1998.

[Kranz, 00] – Kranz, H. G. – "Fundamentals in Computer Aided PD Processing, PD Pattern Recognition and Automated Diagnosis in GIS" , IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7 No. 1, pp. 12-20, Fevereiro 2000.

[Kreuger *et al*, 93] – Kreuger, F. H., Gulski, E., Krivda, A. – "Classification of Partial Discharges" , IEEE Transactions on Electrical Insulation, Vol. 28 No. 6, pp. 917-931, Dezembro 1993.

[Lalitha & Satish, 00] – Lalitha, E. M. & Satish, L. – "Wavelet Analysis for Classification of Multi-source PD Patterns" , IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7 No. 1, pp. 40-47, Fevereiro 2000.

[Lapp & Kranz, 00] – Lapp, A., Kranz H. – "The Use of CIGRE Data Format for PD Diagnosis Applications", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7 No. 1, 102-112, Fevereiro 2000.

[NBR6940, 81] – Associação Brasileira de Normas Técnicas. – "Técnicas de Ensaios Elétricos de Alta-Tensão – Medição de Descargas Parciais", 1981.

[Papoulis, 91] – Papoulis, Athanasios – "Probability, Random Variables, and Sthochastic Processes", IE-McGraw-Hill UK, 3° Edição 1991.

[Russell & Norvig, 95] – Russell, S., Norvig, P. – "Artificial Intelligence, A modern Approach" – Prentice-Hall, New Jersey –1995.

[Satish & Zaengl, 94] – Satish, L., Zaengl, W. – "Artificial Neural Networks for Recognition of 3-d Partial Discharge Patterns", IEEE Transactions on Electrical Insulation, Vol. 1 No. 2, pp. 265-275, Abril 1994.

[Solvay, 95] – Catálogo com informações técnicas sobre o SF_6 do fabricante alemão Solvay Fluor Und Derivate GmbH, 1995.

[Stone, 00] – Stone, G. - "Importance of Bandwidth in PD Measurement in Operating Motors and Generators", IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7 No. 1, pp. 6-11, Fevereiro 2000.

[Takahashi *et al*, 00] – Takahashi T., Yamada, T., Hayakawa, N., Okubo, H. – "Space charge behavior in SF6 gas and sequential generation od PD pulses" , IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 7 No. 1, pp. 141-145, Fevereiro 2000.

[Tettex, 85] – Catálogo do fabricante de instrumentos, Tettex AG - Switzerland, publicação TT9120 d/f/e-30, dezembro 1985.

[Weiss & Kulikowski, 91] – Weiss, Sholom M., Kulikouwski, Casimir A. – "Computer Systems That Learn", Morgan Kaufmann Publishers, Inc. San Mateo, California – 1991.

7 – ANEXO I

Gráficos com SSE ("Sum of Square Error") referentes aos Treinamentos e Validações das Redes Neurais

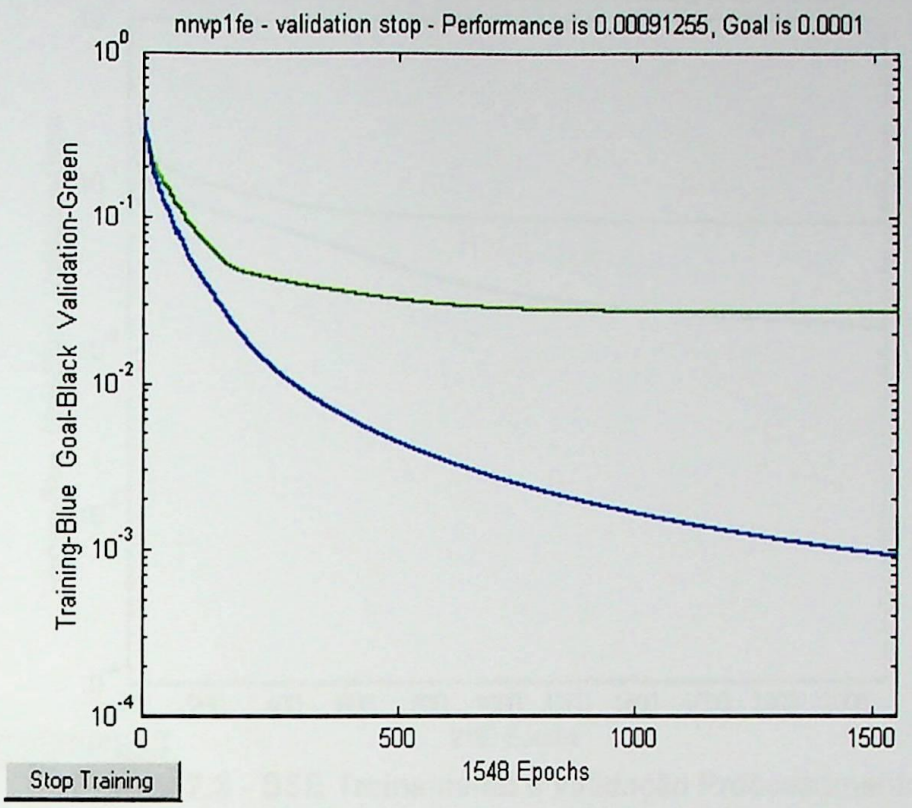


Figura 7.1 – SSE Treinamento e Validação Processamento 4.1 NN-FE-15x8x2

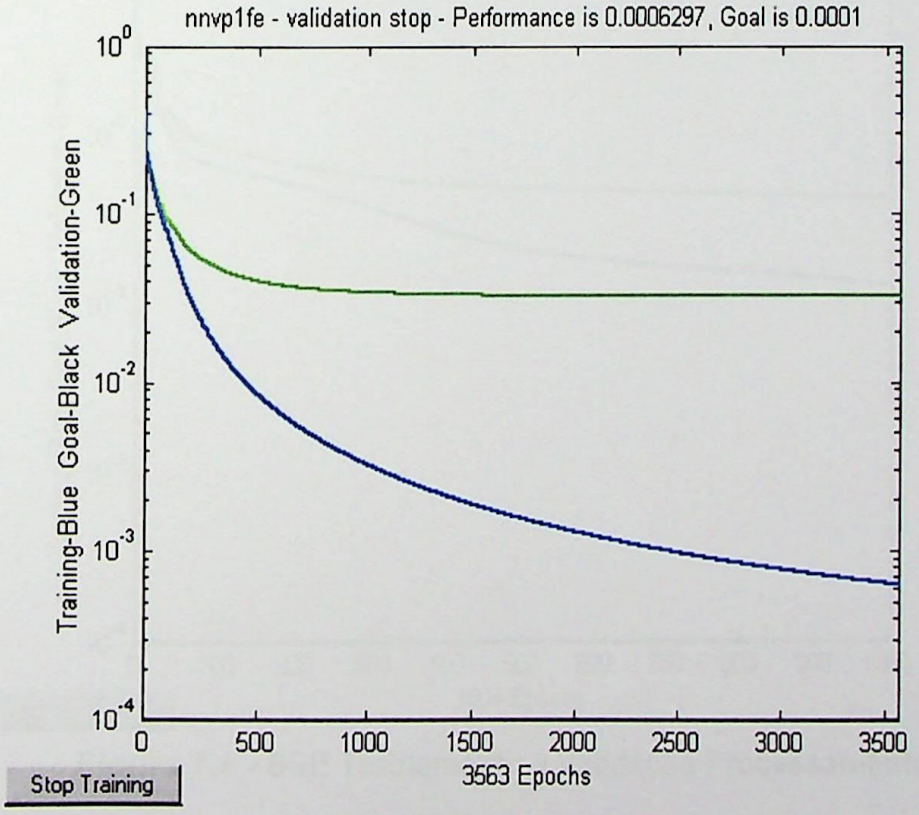


Figura 7.2 - SSE Treinamento e Validação Processamento 4.1 NN-FE-15x8x4x2

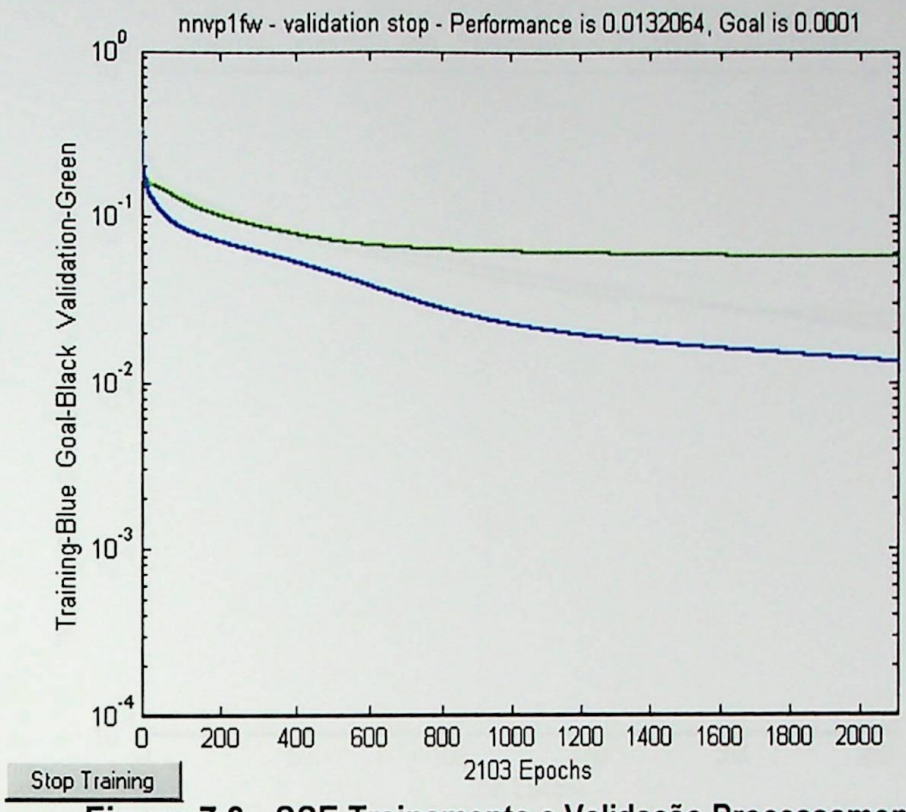


Figura 7.3 - SSE Treinamento e Validação Processamento 4.1 NN-FW-15x8x2

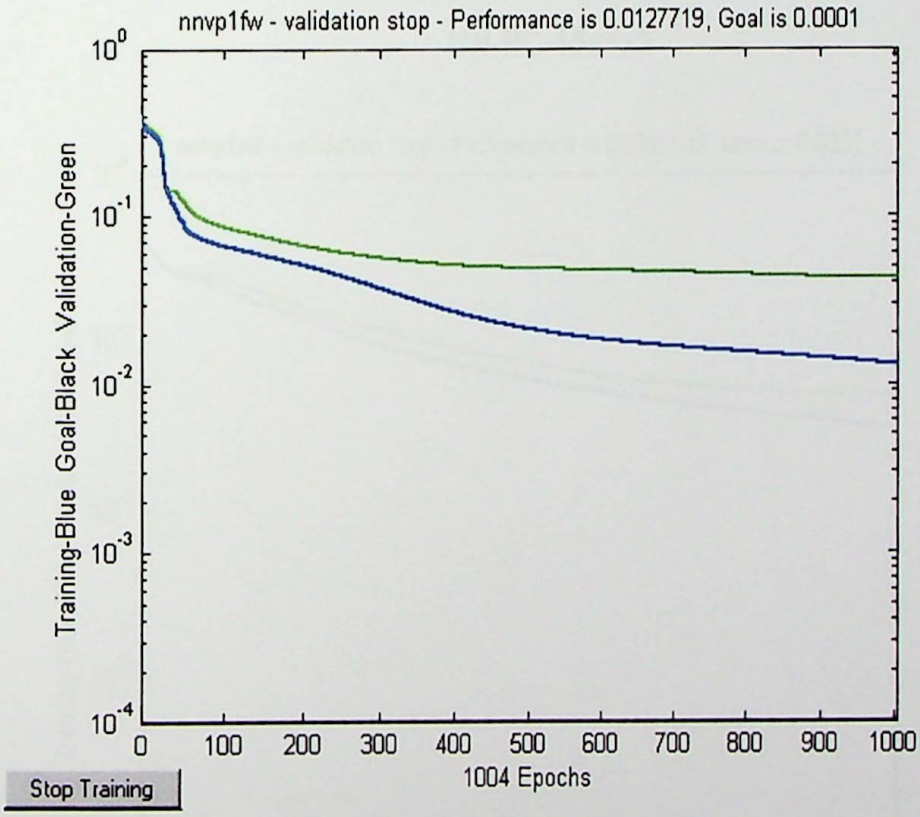


Figura 7.4 - SSE Treinamento e Validação Processamento 4.1 NN-FW-15x8x4x2

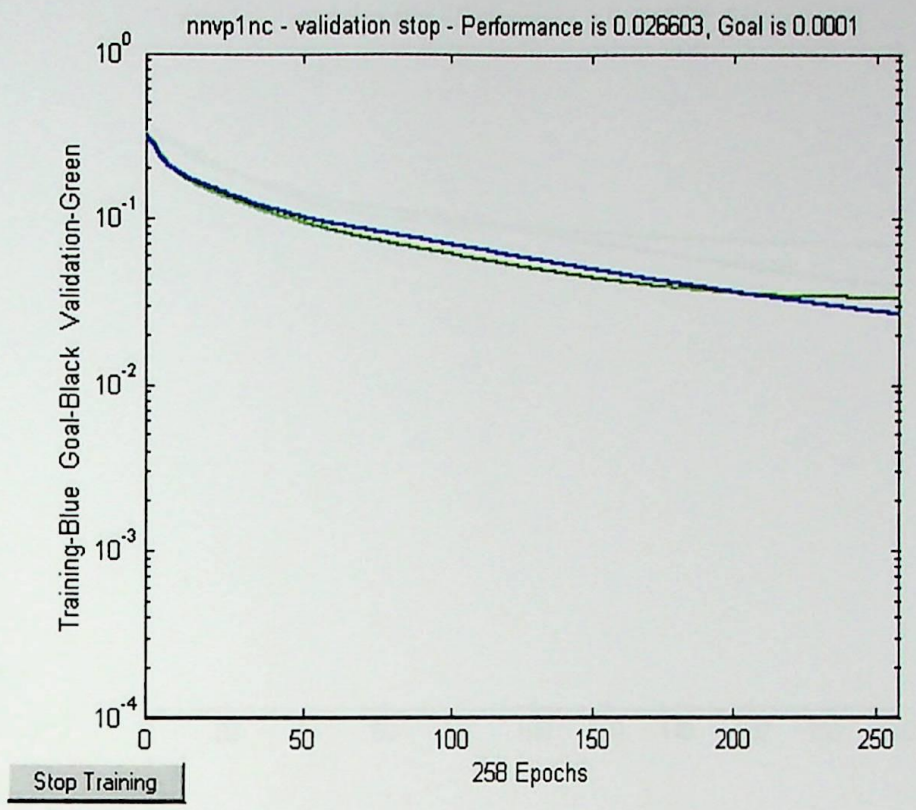


Figura 7.5 - SSE Treinamento e Validação Processamento 4.1

NN-NC-15x8x2

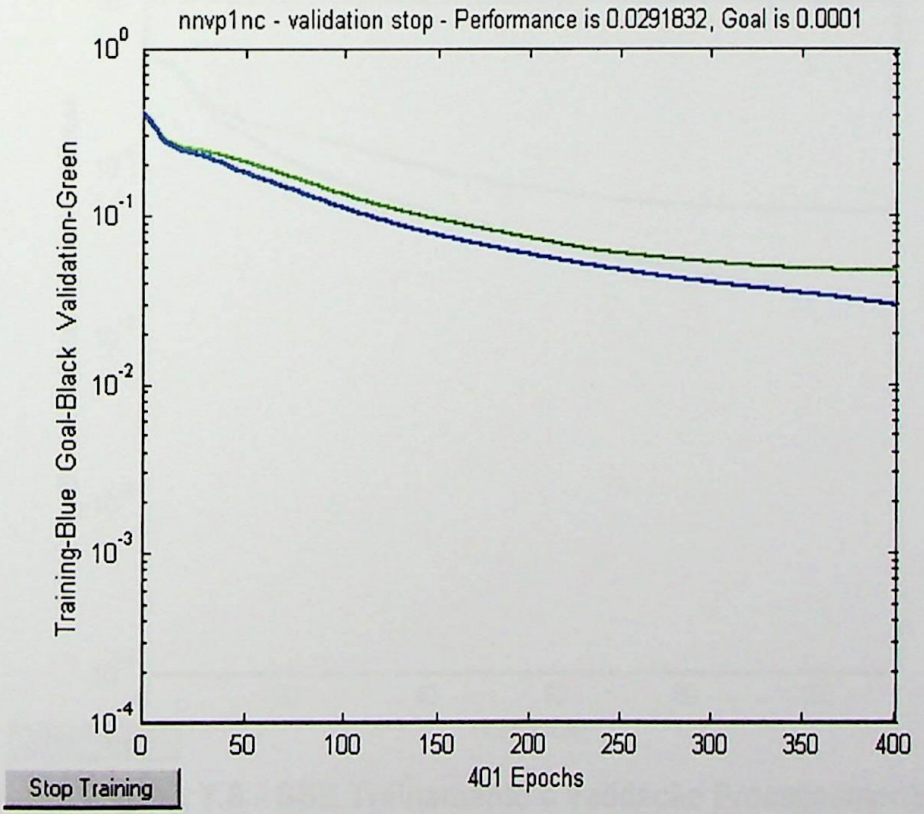


Figura 7.6 - SSE Treinamento e Validação Processamento 4.1

NN-NC-15x8x4x2

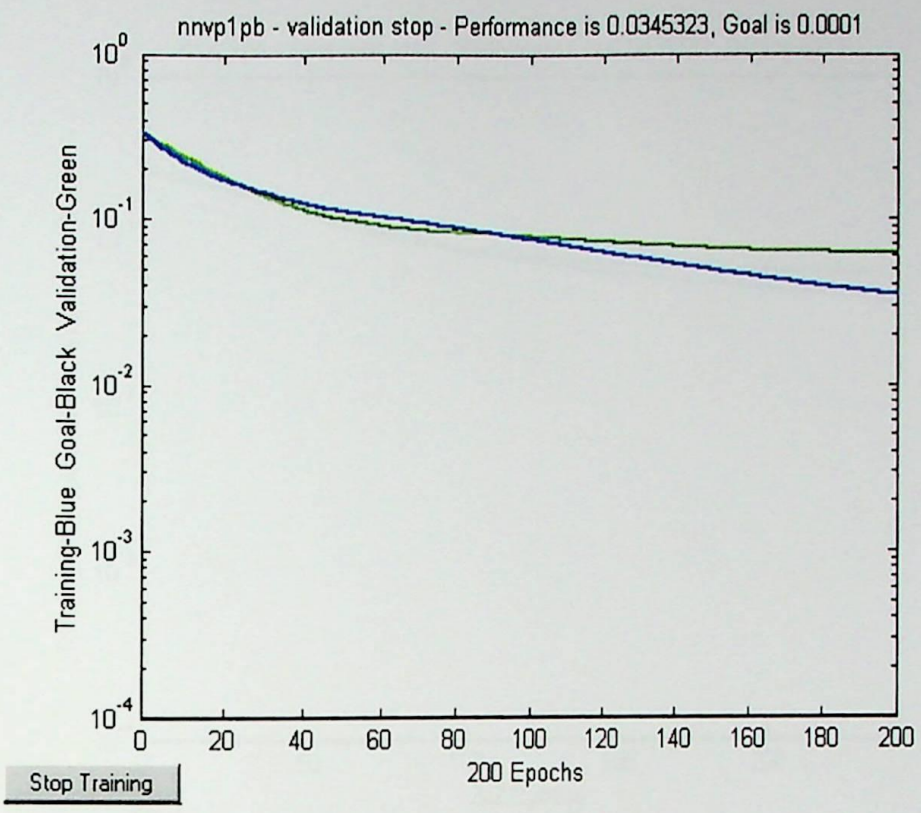


Figura 7.7 - SSE Treinamento e Validação Processamento 4.1

NN-PB-15x8x2

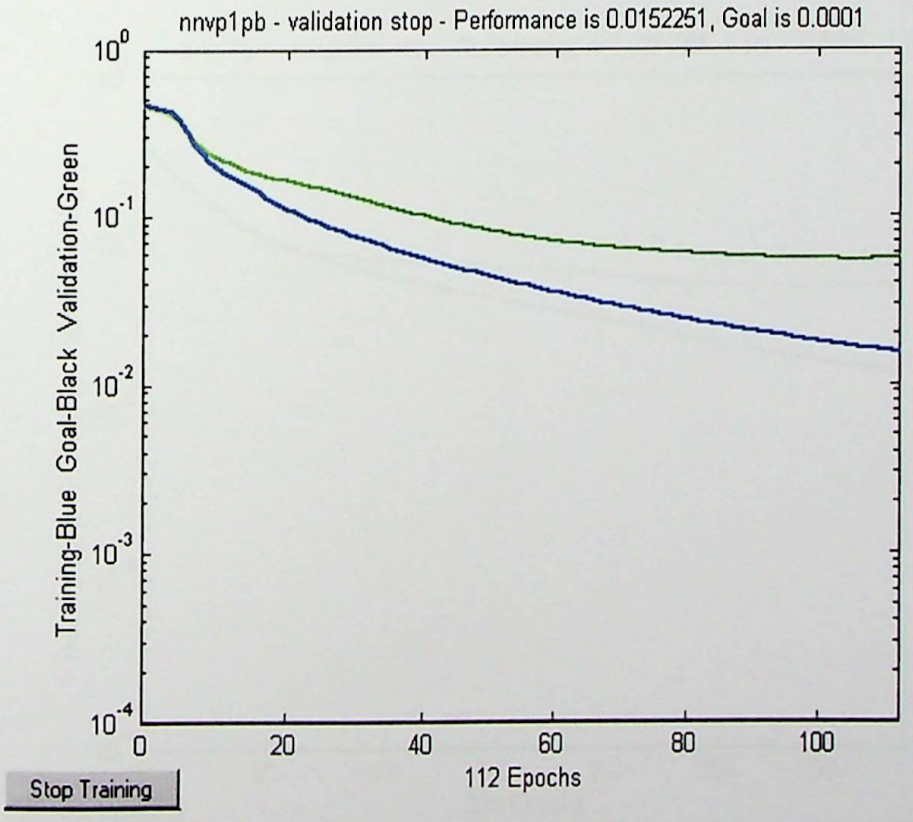


Figura 7.8 - SSE Treinamento e Validação Processamento 4.1

NN-PB-15x8x4x2

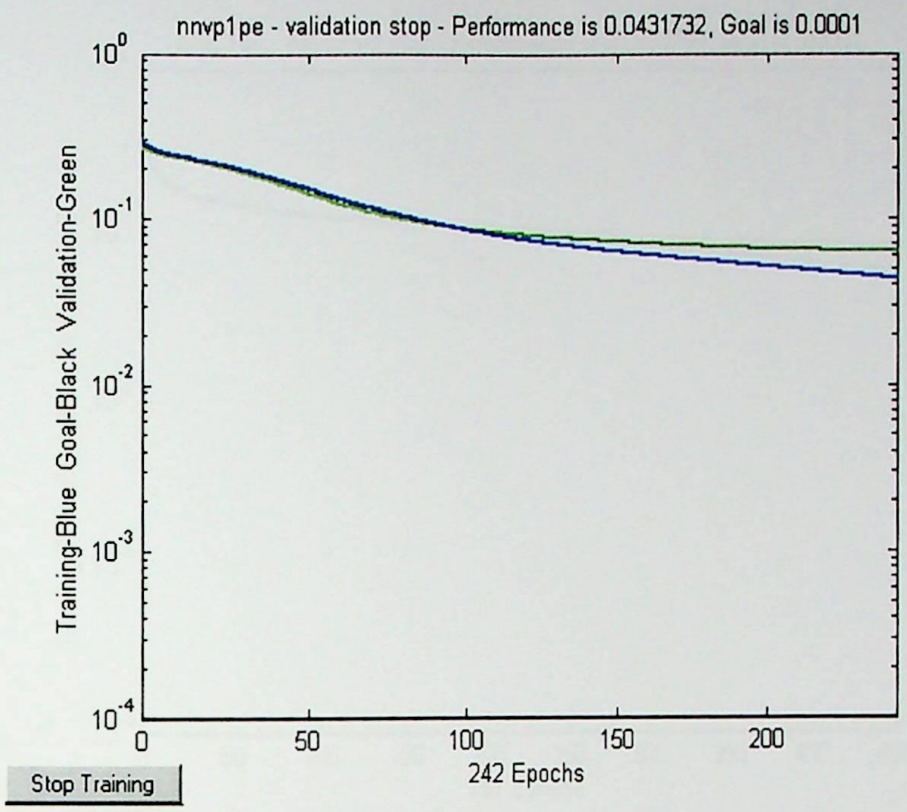


Figura 7.9 - SSE Treinamento e Validação Processamento 4.1

NN-PE-15x8x2

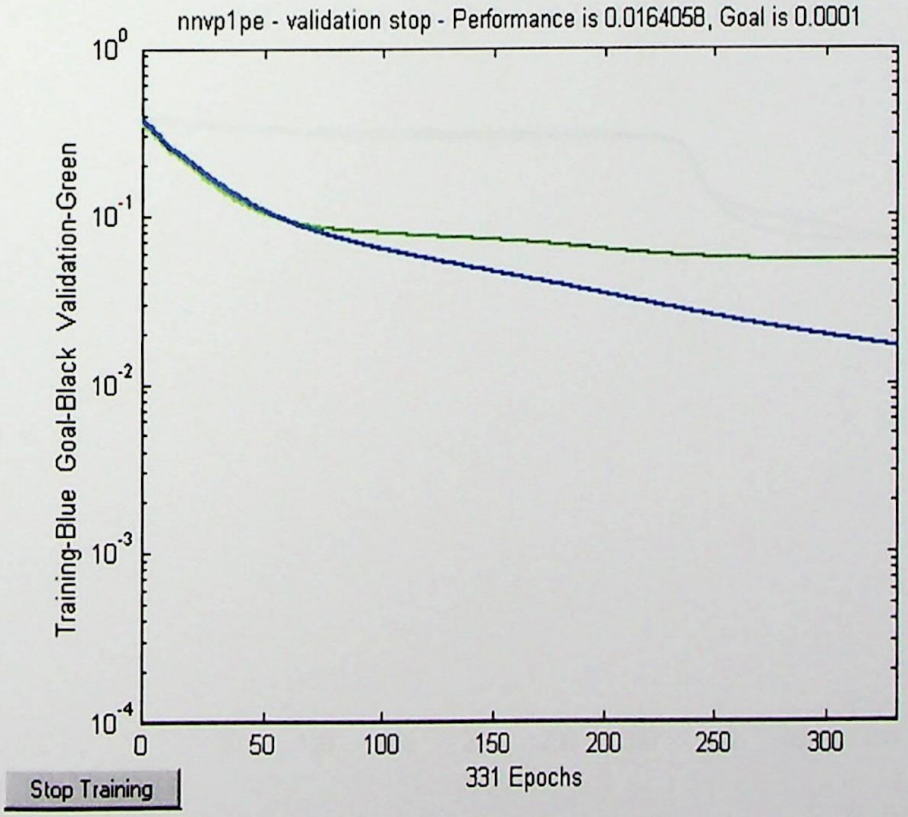


Figura 7.10 - SSE Treinamento e Validação Processamento 4.1

NN-PE-15x8x4x2

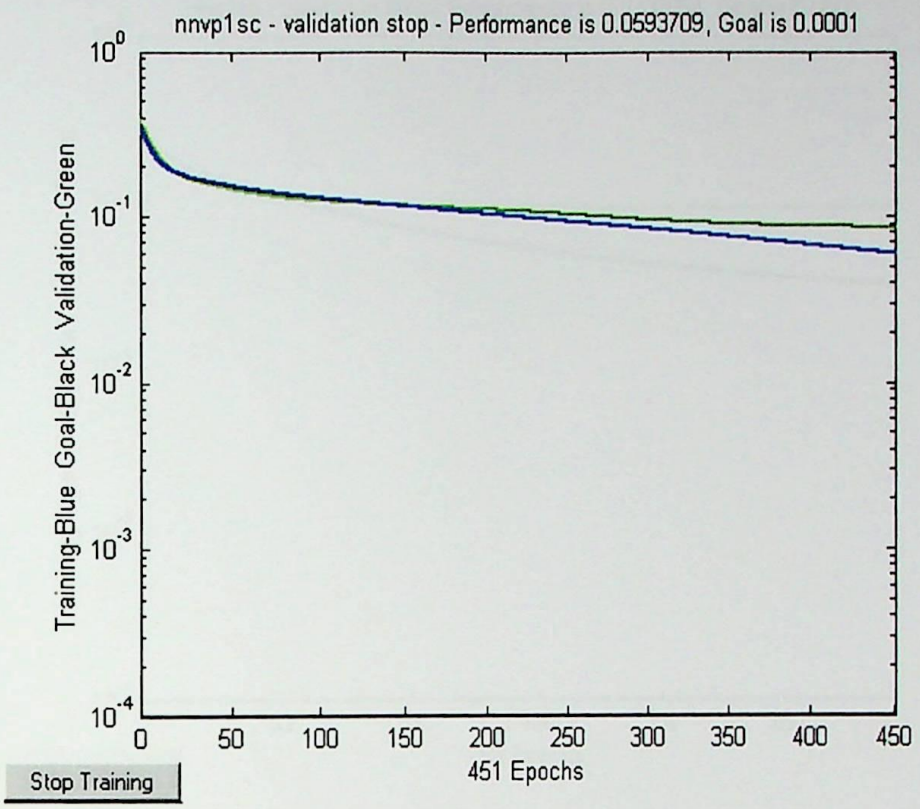


Figura 7.11 - SSE Treinamento e Validação Processamento 4.1

NN-SC-15x8x2

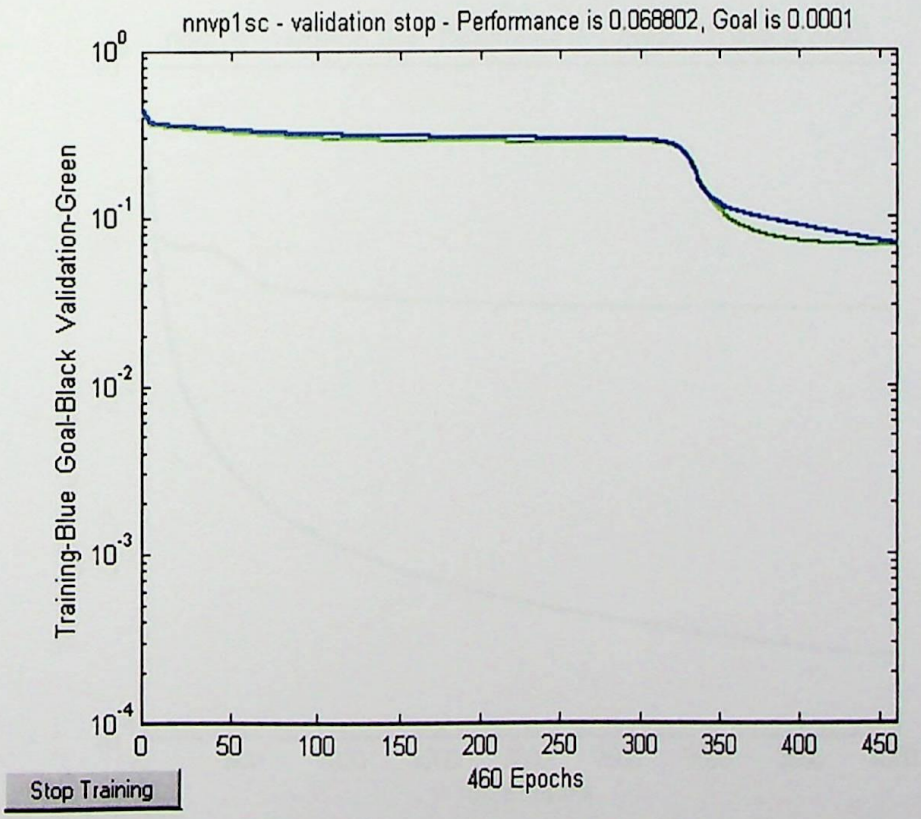


Figura 7.12 - SSE Treinamento e Validação Processamento 4.1

NN-SC-15x8X4x2

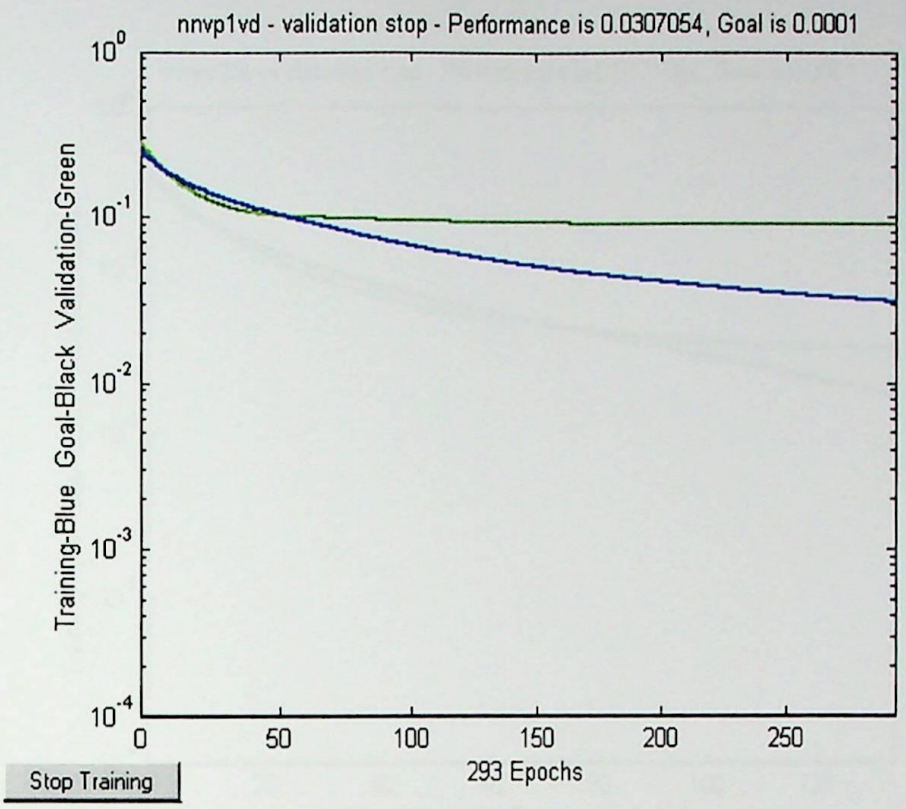


Figura 7.13 - SSE Treinamento e Validação Processamento 4.1

NN-VD-15x8x2

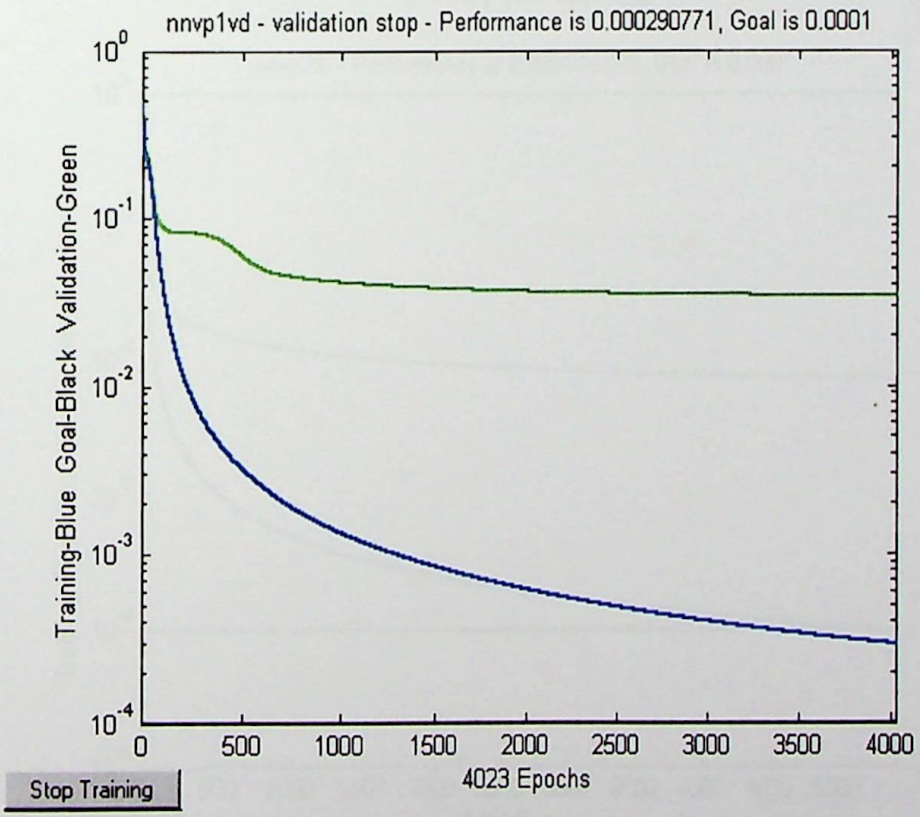


Figura 7.14 - SSE Treinamento e Validação Processamento 4.1

NN-VD-15x8X4x2

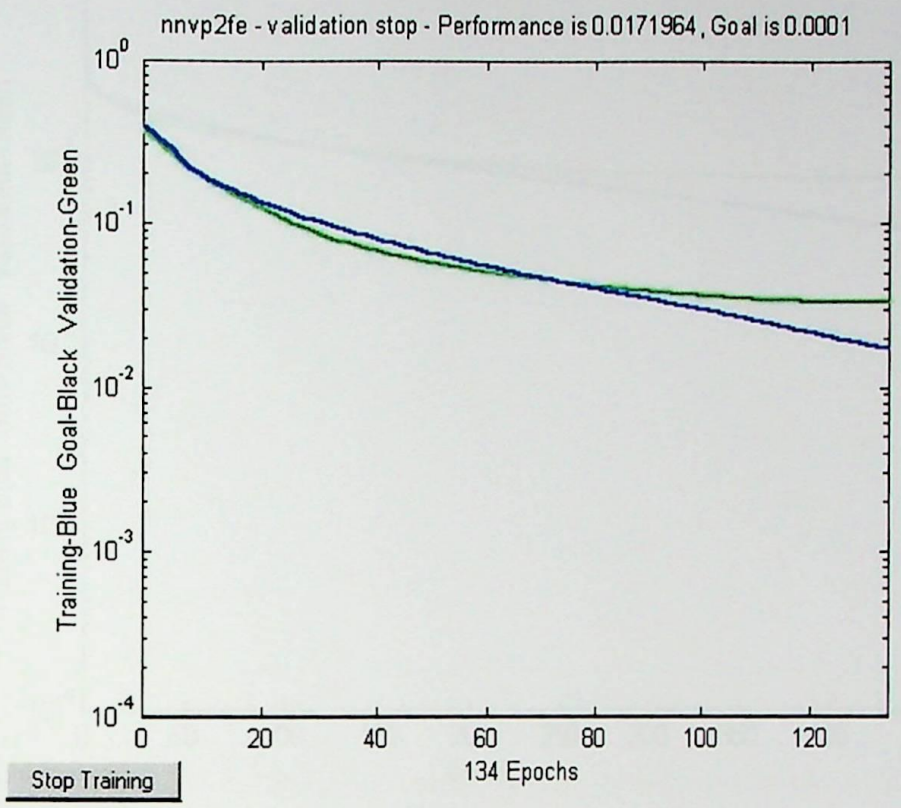


Figura 7.15 - SSE Treinamento e Validação Processamento 4.1.1 NN-FE-15x8x2

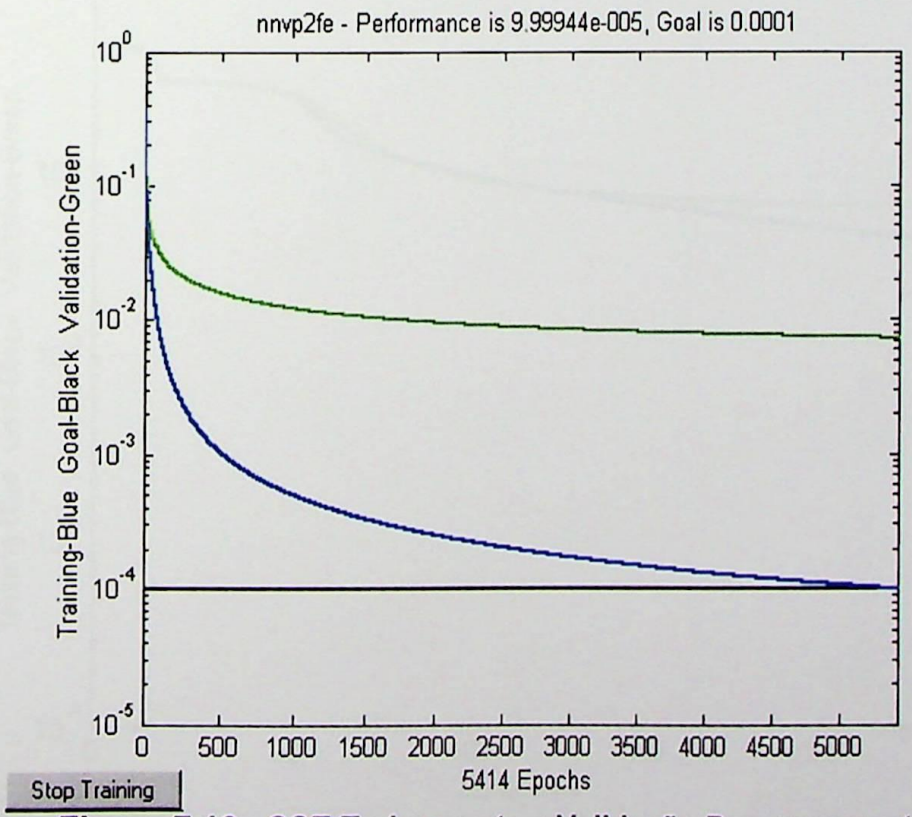


Figura 7.16 - SSE Treinamento e Validação Processamento 4.1.1 NN-FE-15x8X4x2

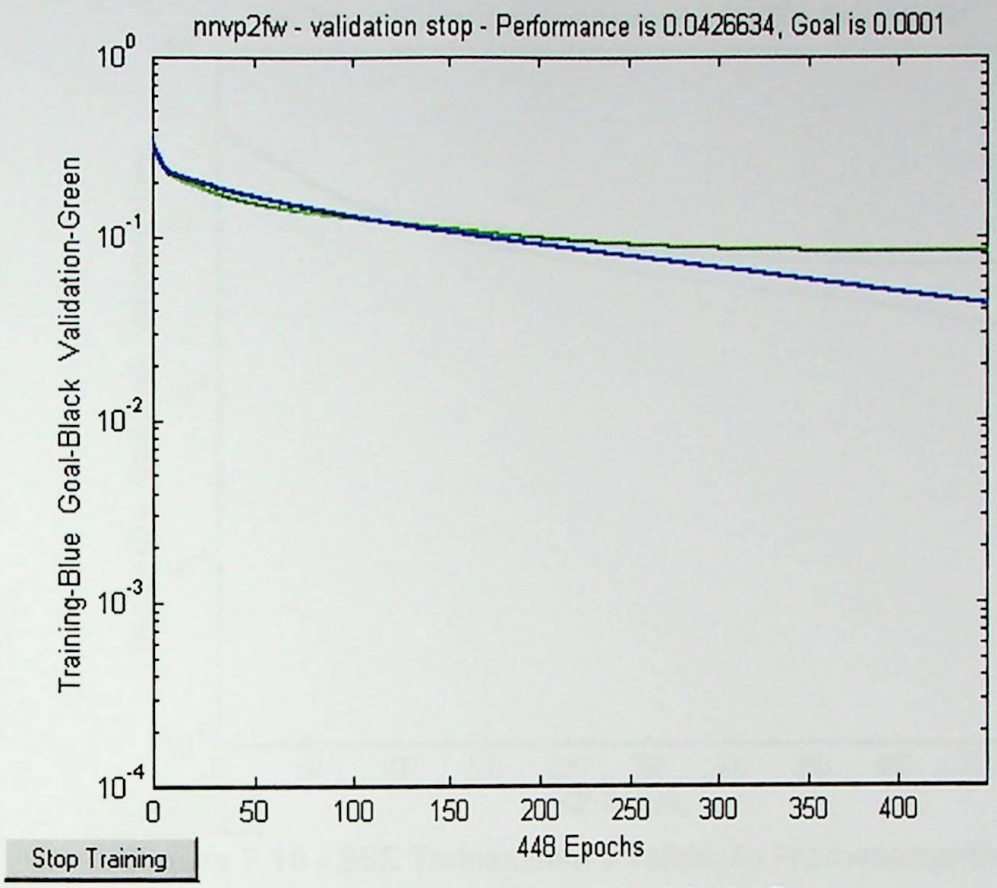


Figura 7.17 - SSE Treinamento e Validação Processamento 4.1.1 NN-FW-15x8x2

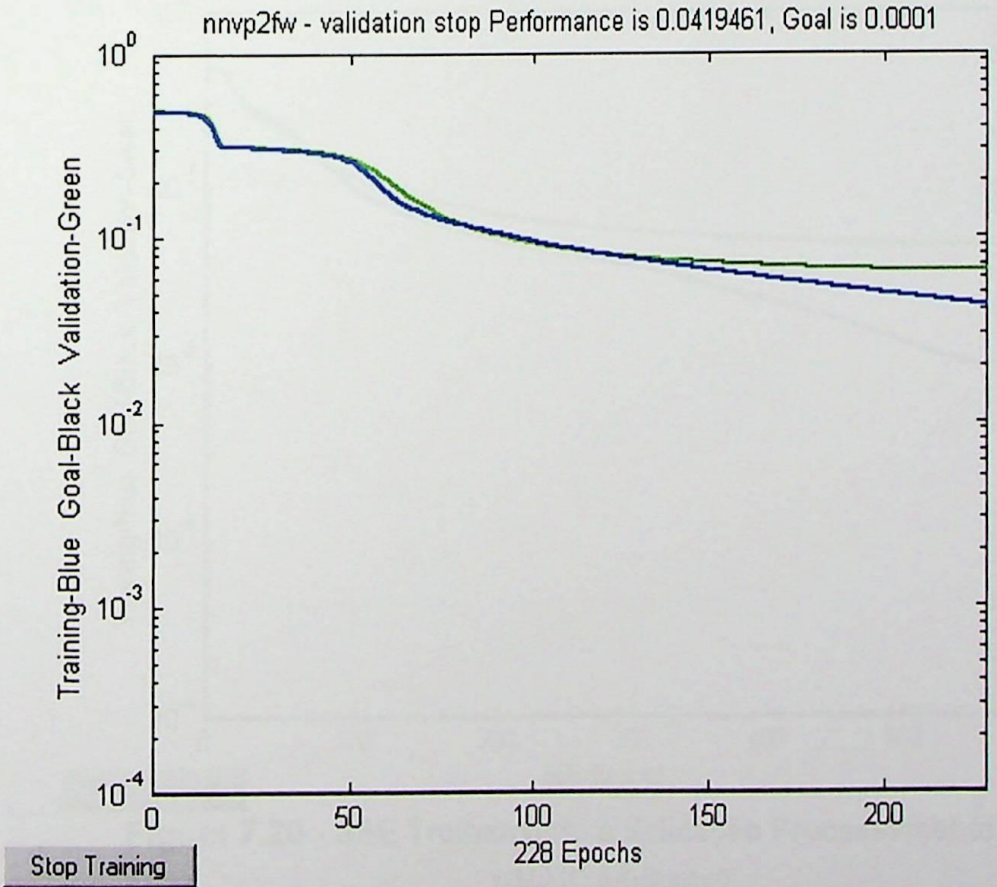


Figura 7.18 - SSE Treinamento e Validação Processamento 4.1.1 NN-FW-15x8x4x2

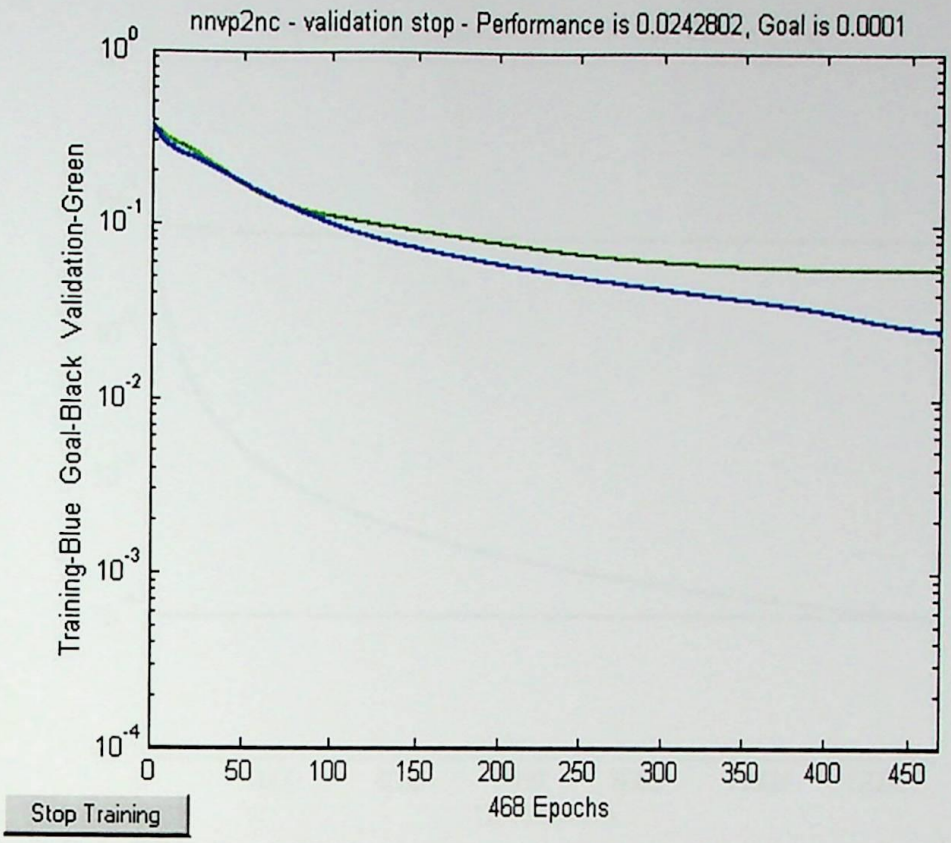


Figura 7.19 - SSE Treinamento e Validação Processamento 4.1.1 NN-NC-15x8x2

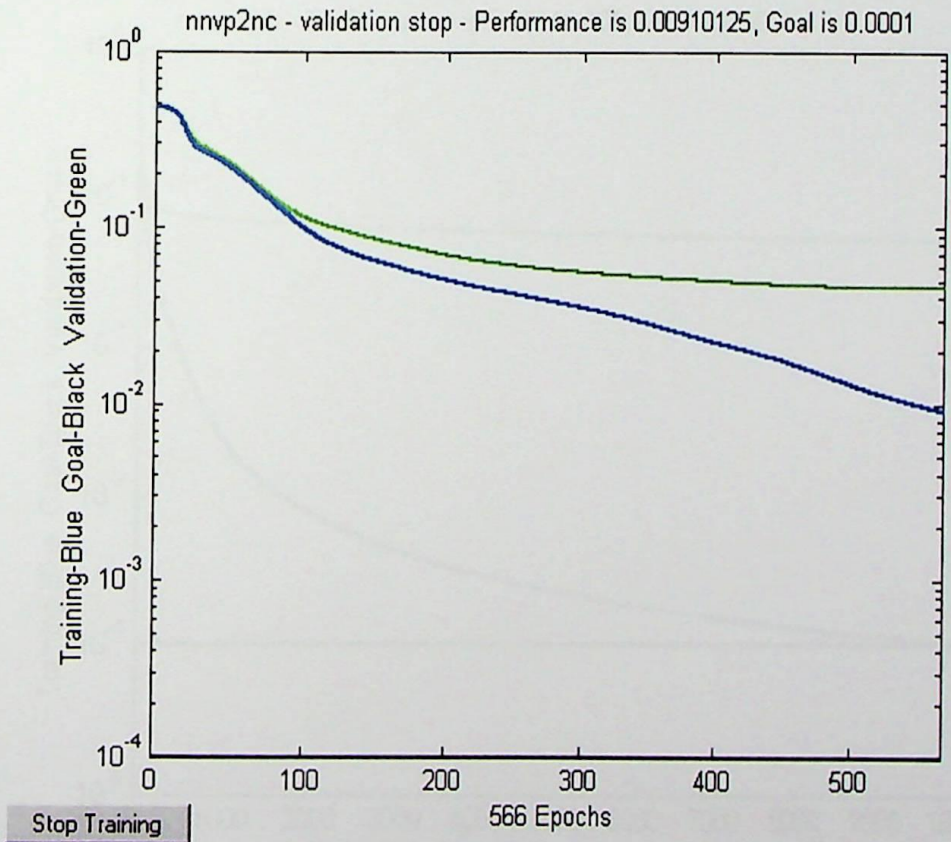


Figura 7.20 - SSE Treinamento e Validação Processamento 4.1.1 NN-NC-15x8x4x2

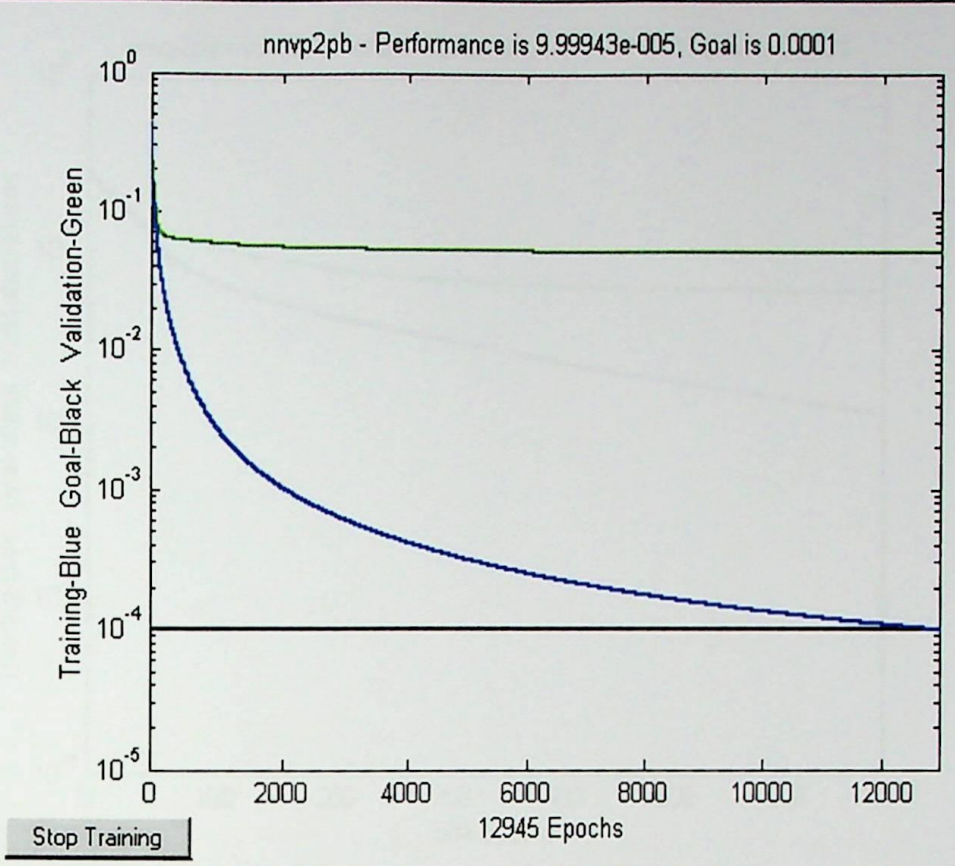


Figura 7.21 - SSE Treinamento e Validação Processamento 4.1.1 NN-PB-15x8x2

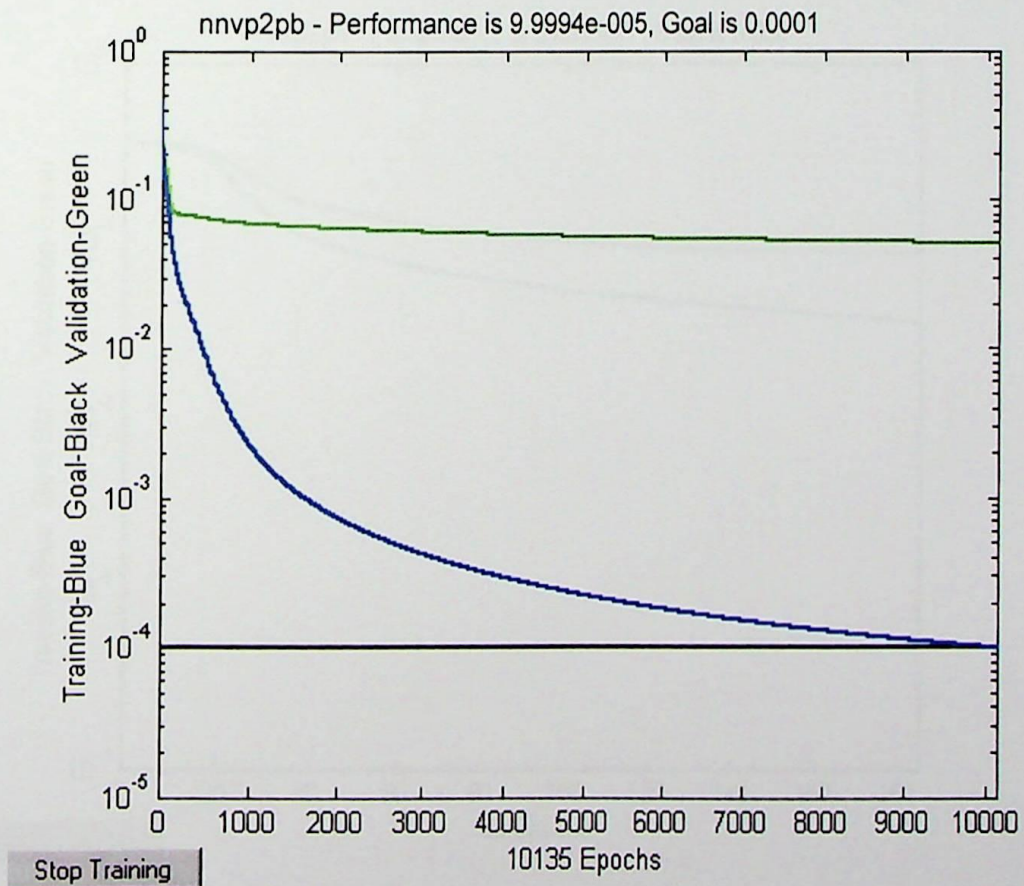


Figura 7.22 - SSE Treinamento e Validação Processamento 4.1.1 NN-PB-15x8x4x2

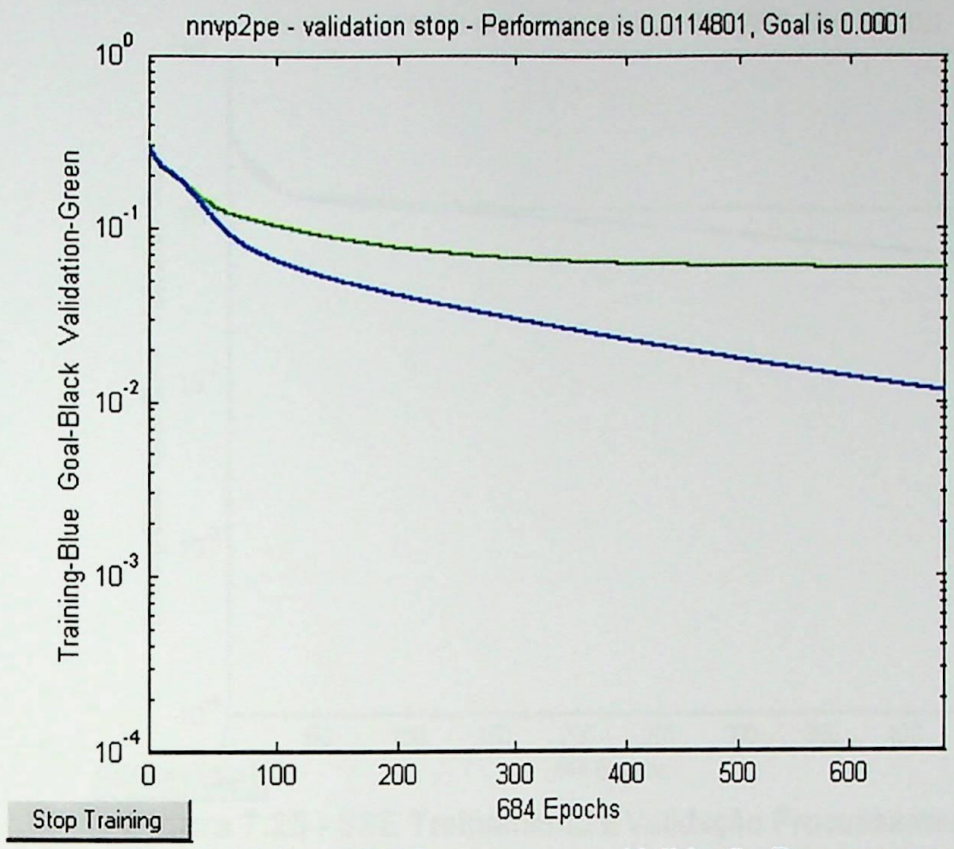


Figura 7.23 - SSE Treinamento e Validação Processamento 4.1.1 NN-PE-15x8x2

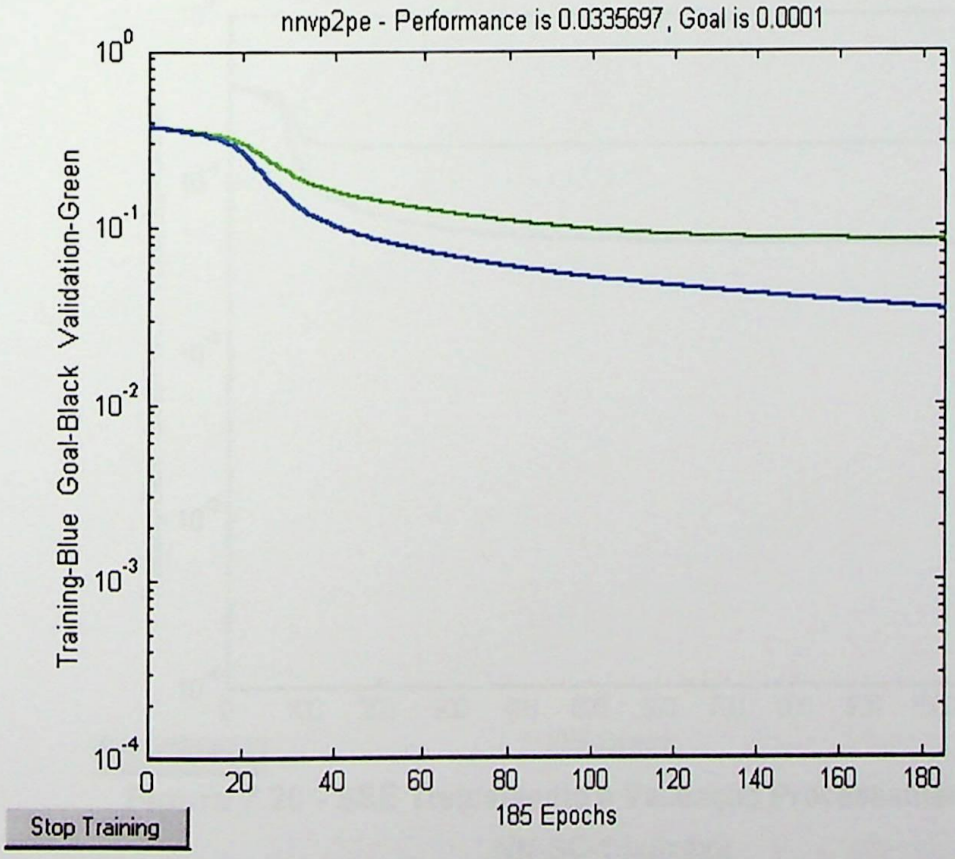


Figura 7.24 - SSE Treinamento e Validação Processamento 4.1.1 NN-PE-15x8x4x2

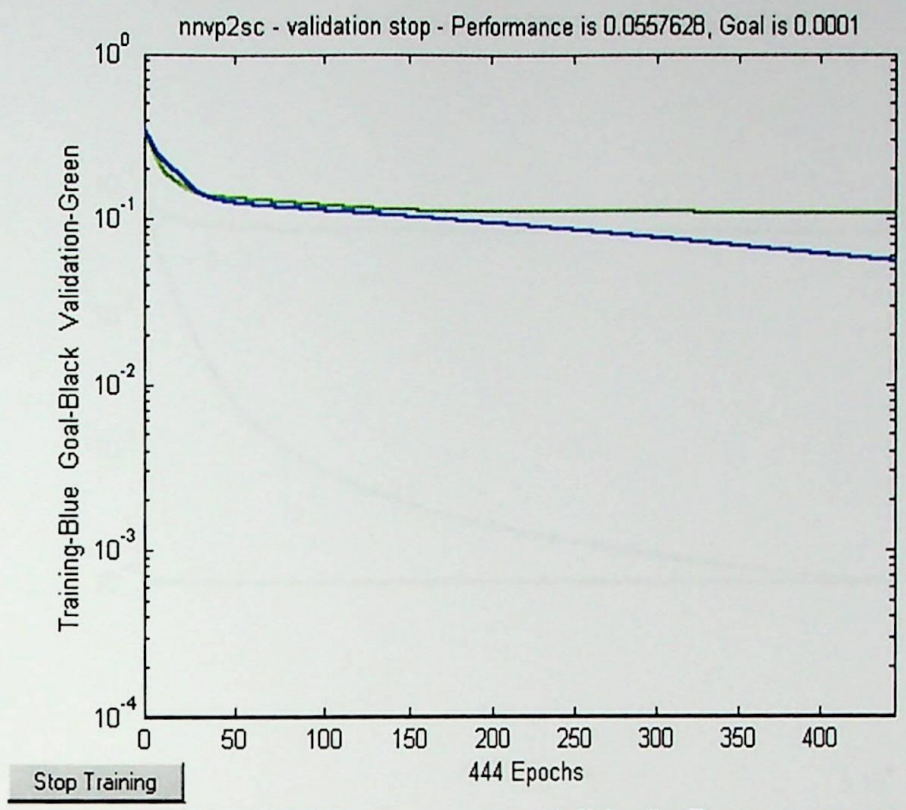


Figura 7.25 - SSE Treinamento e Validação Processamento 4.1.1 NN-SC-15x8x2

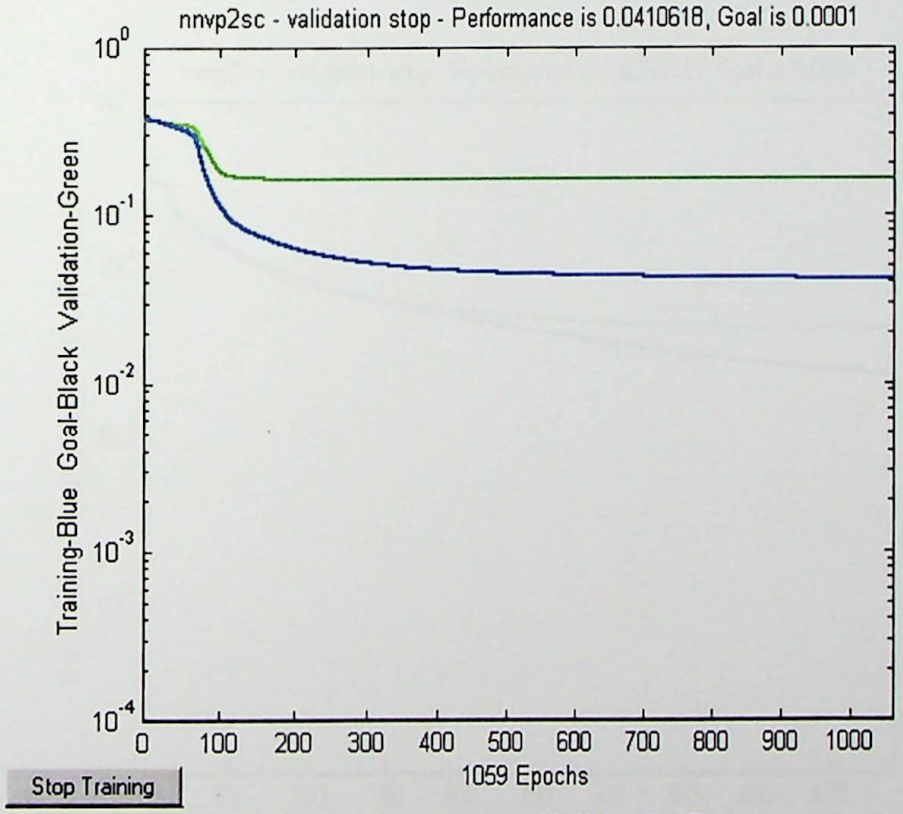


Figura 7.26 - SSE Treinamento e Validação Processamento 4.1.1 NN-SC-15x8x4x2

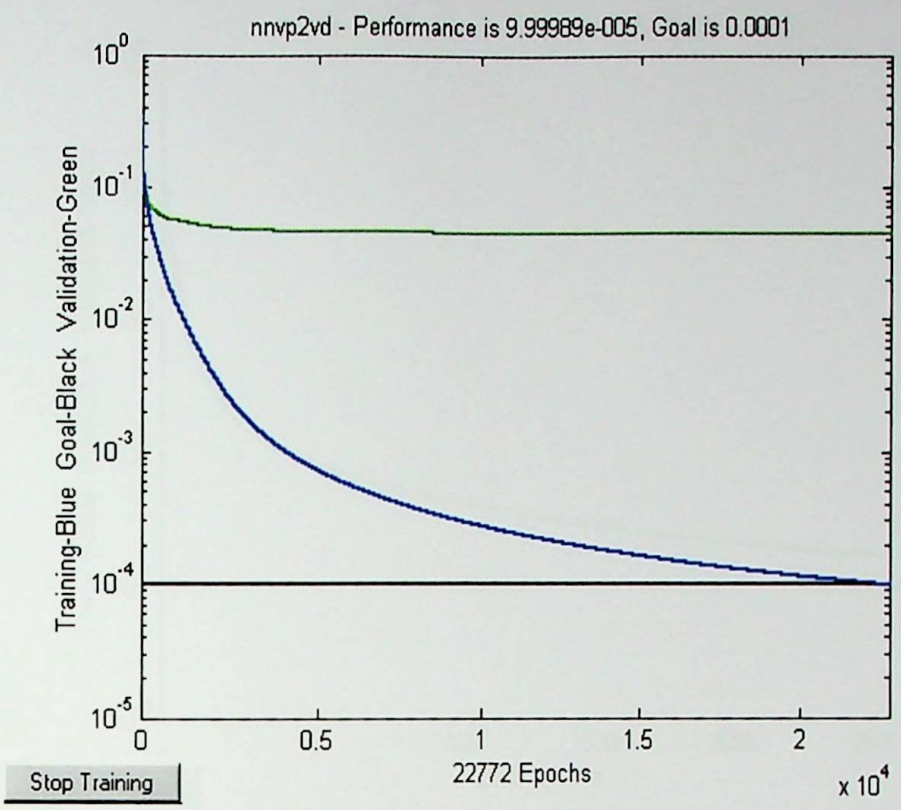


Figura 7.27 - SSE Treinamento e Validação Processamento 4.1.1 NN-VD-15x8x2

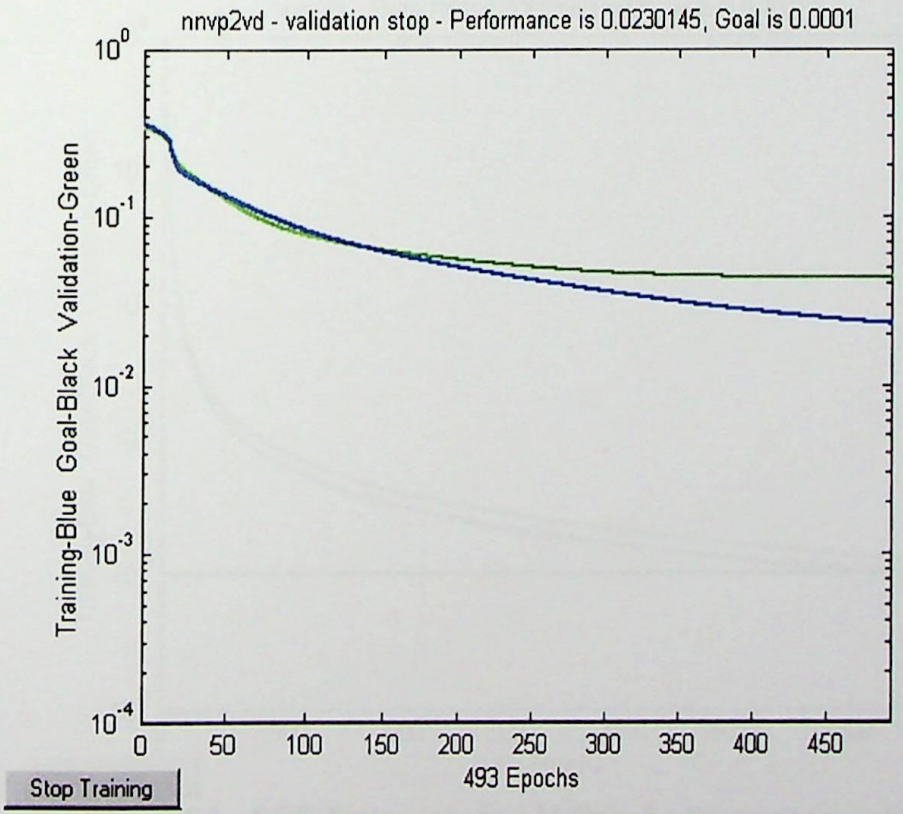


Figura 7.28 - SSE Treinamento e Validação Processamento 4.1.1 NN-VD-15x8x4x2

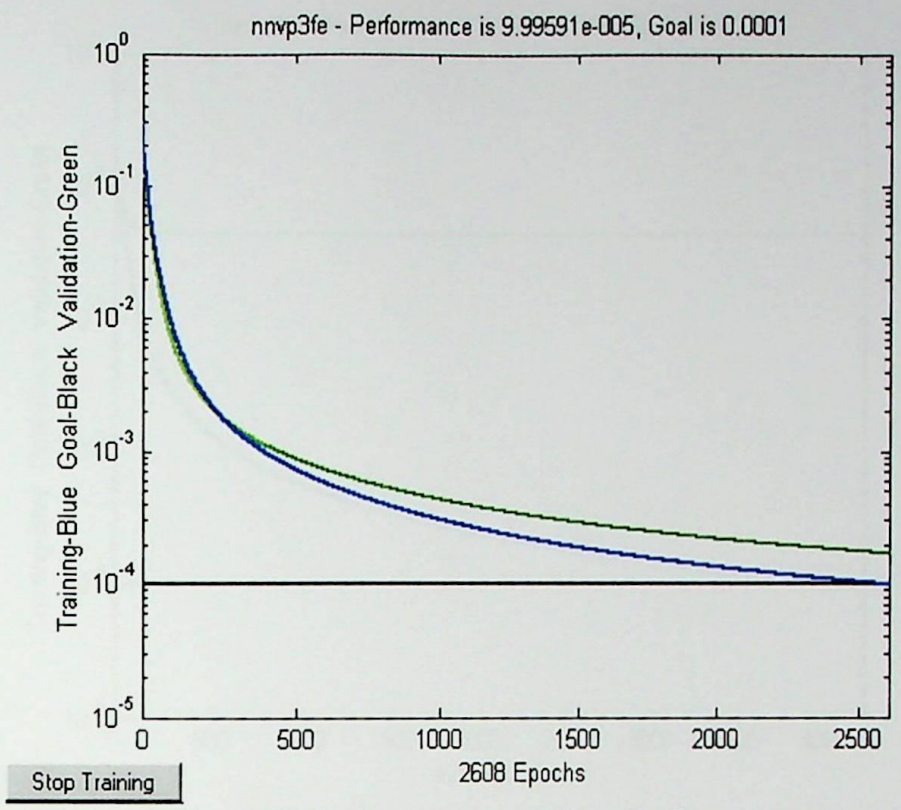


Figura 7.29 - SSE Treinamento e Validação Processamento 4.1.2 NN-FE-32x8x2

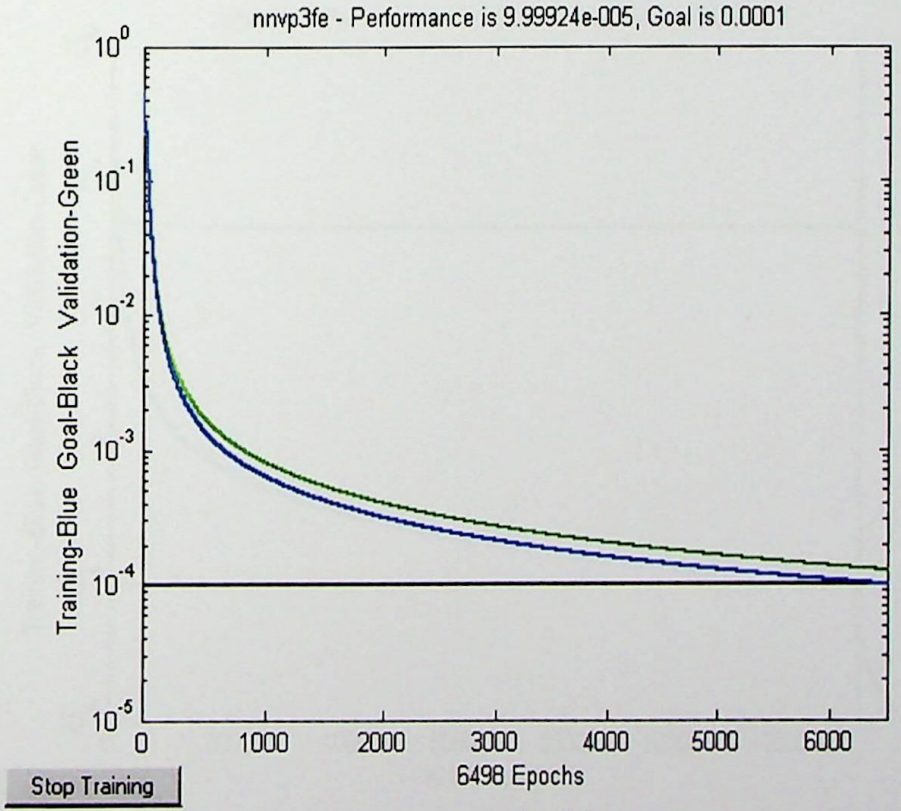


Figura 7.30 - SSE Treinamento e Validação Processamento 4.1.2 NN-FE-32x8x4x2

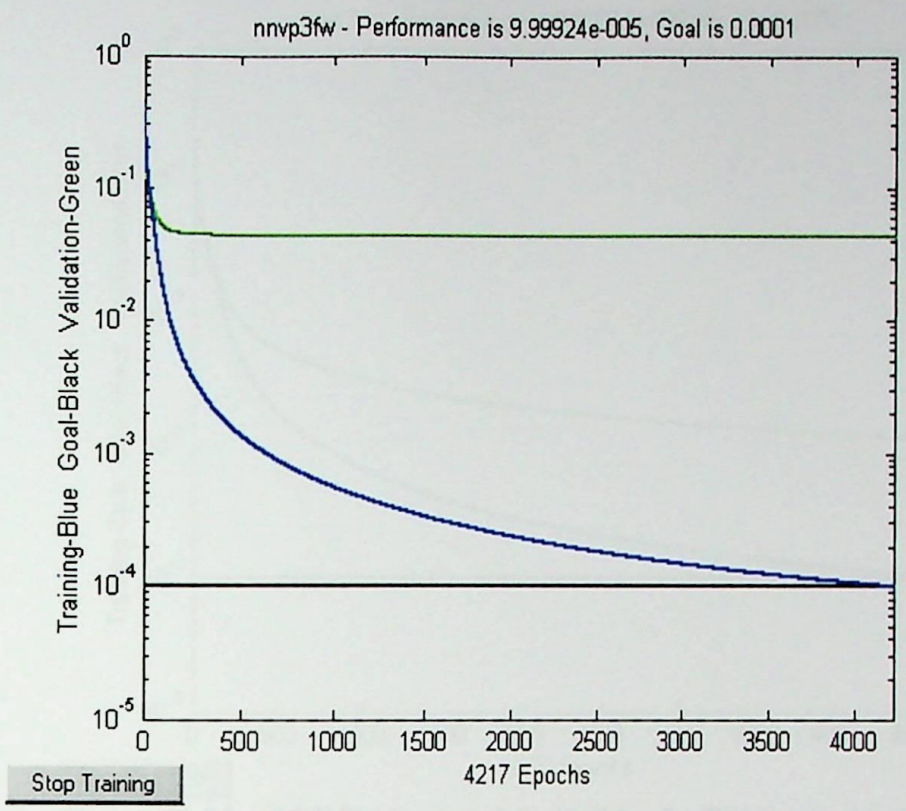
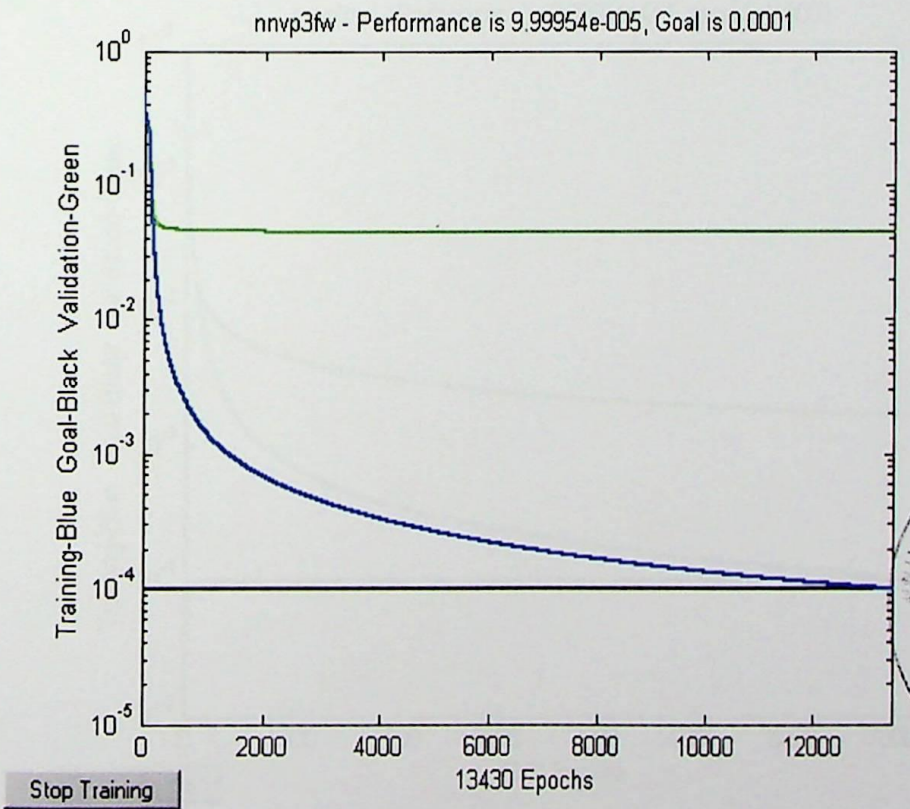


Figura 7.31 - SSE Treinamento e Validação Processamento 4.1.2 NN-FW-32x8x2



UNIVERSIDADE FEDERAL DE ITAJUBÁ
Biblioteca
UNIFEI

Figura 7.32 - SSE Treinamento e Validação Processamento 4.1.2 NN-FW-32x8x4x2

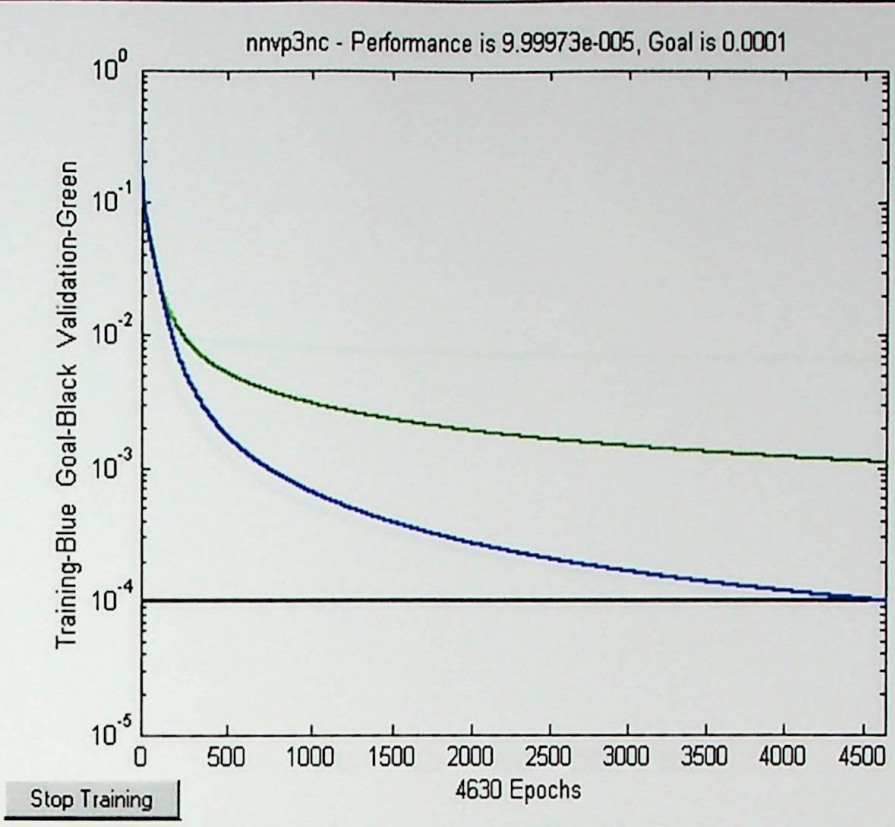


Figura 7.33 - SSE Treinamento e Validação Processamento 4.1.2 NN-NC-32x8x2

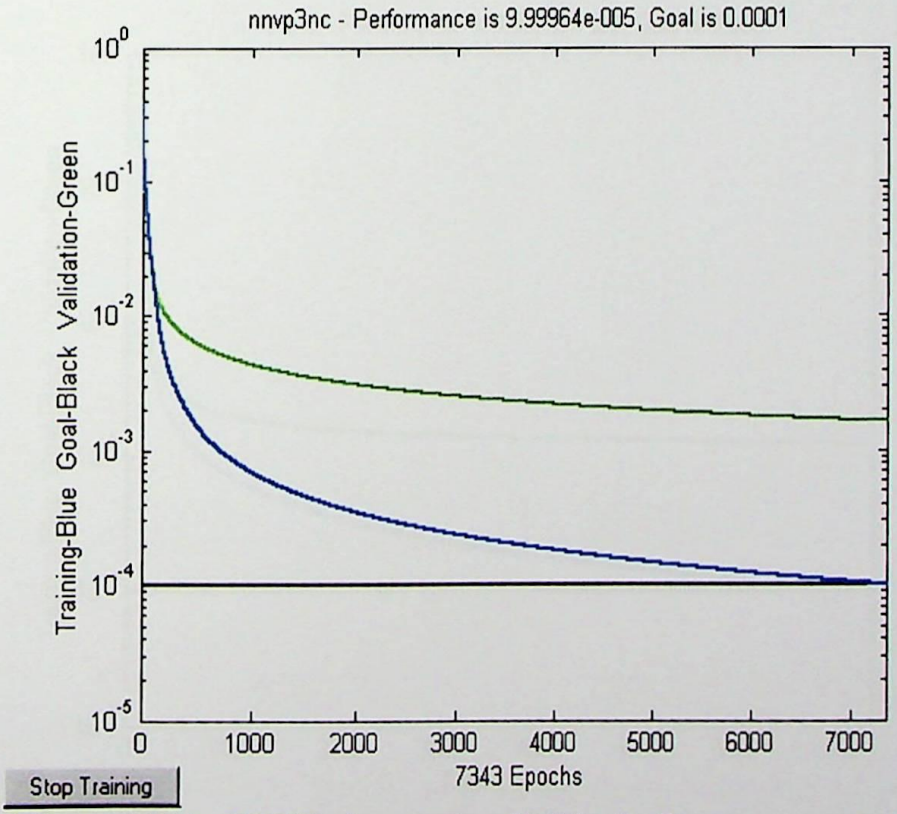


Figura 7.34 - SSE Treinamento e Validação Processamento 4.1.2 NN-NC-32x8x4x2

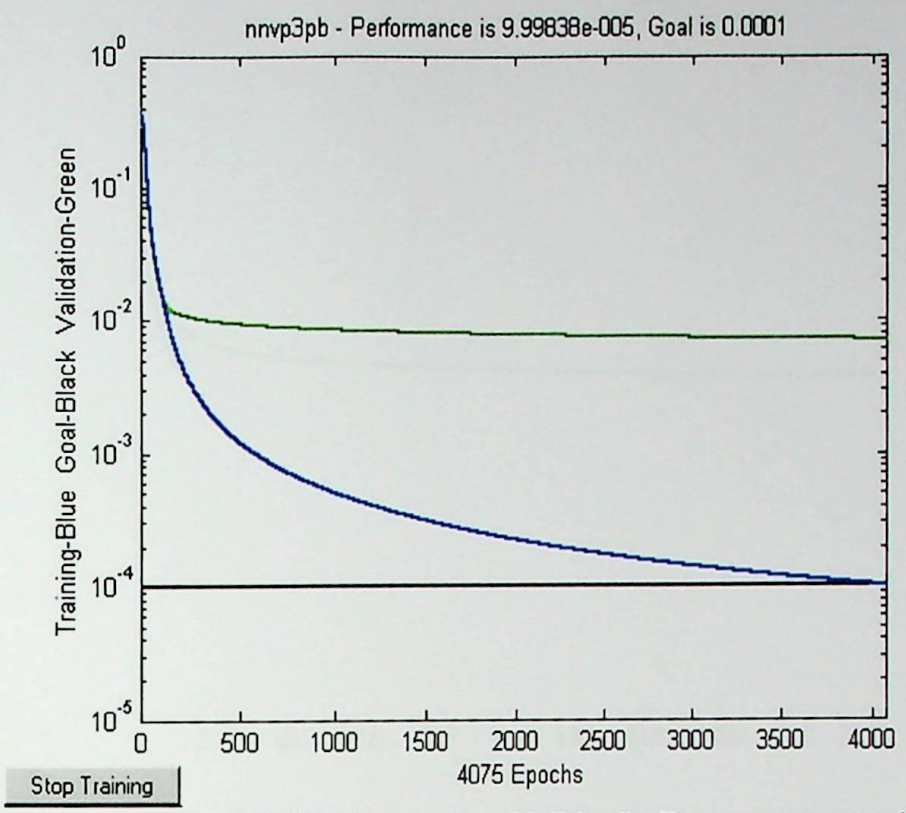


Figura 7.35 - SSE Treinamento e Validação Processamento 4.1.2 NN-PB-32x8x2

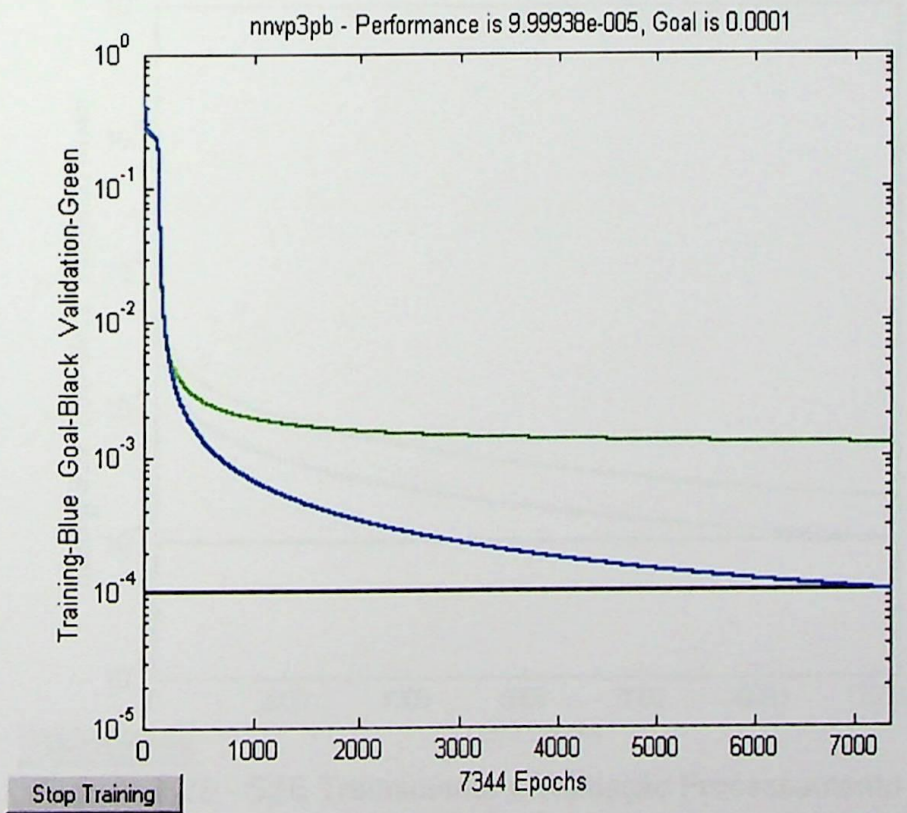


Figura 7.36 - SSE Treinamento e Validação Processamento 4.1.2 NN-PB-32x8x4x2

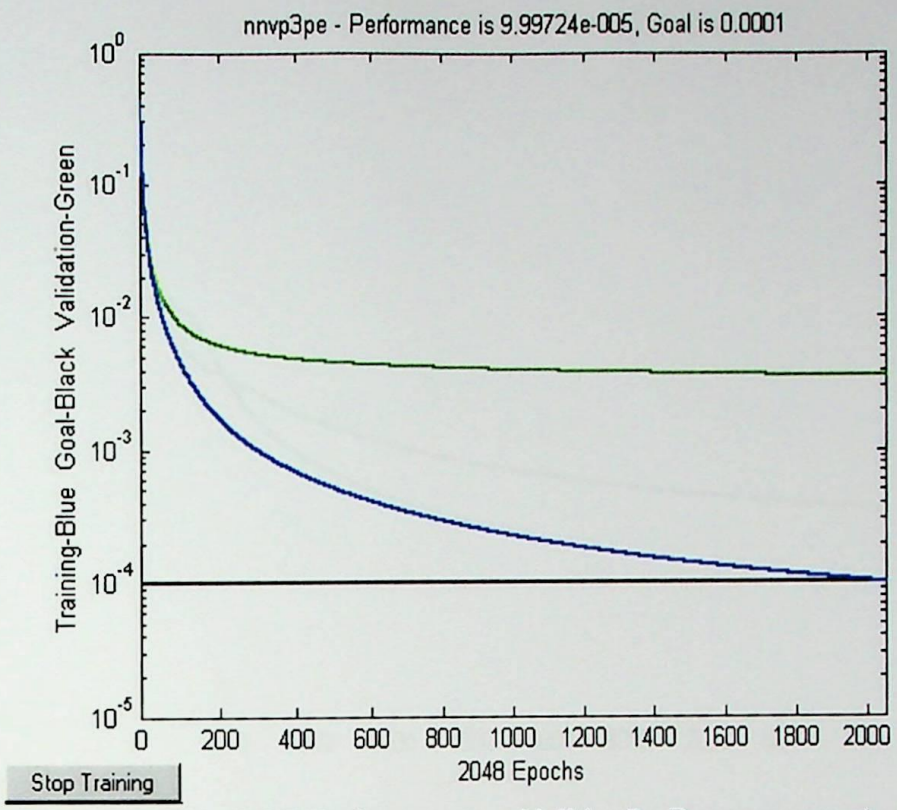


Figura 7.37 - SSE Treinamento e Validação Processamento 4.1.2 NN-PE-32x8x2

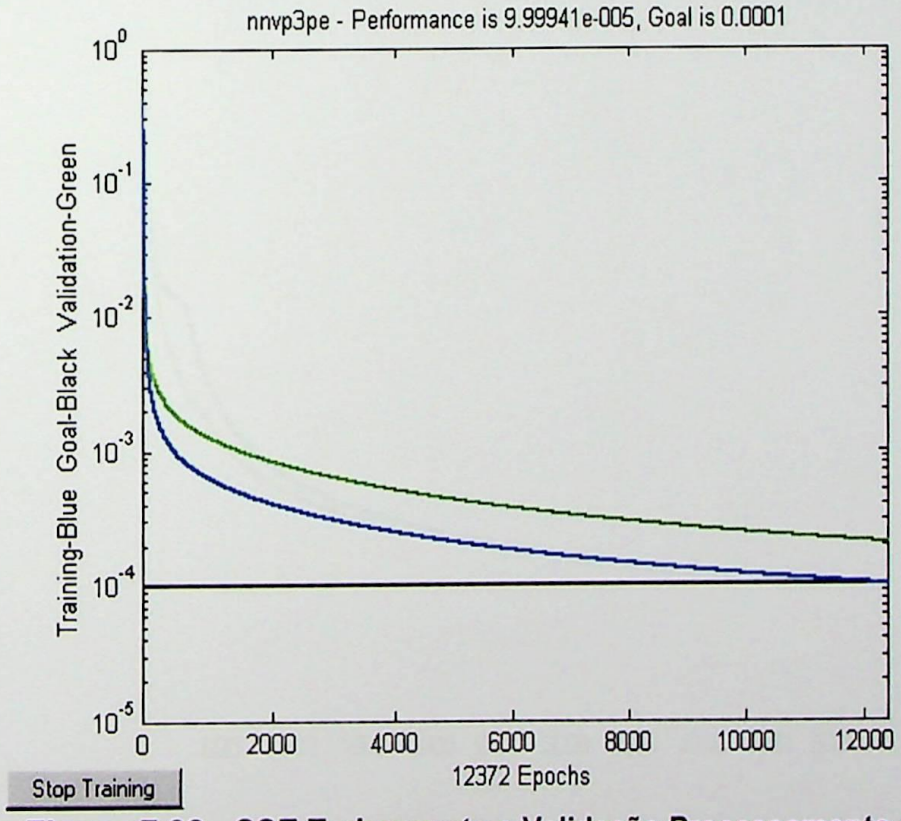


Figura 7.38 - SSE Treinamento e Validação Processamento 4.1.2 NN-PE-32x8x4x2

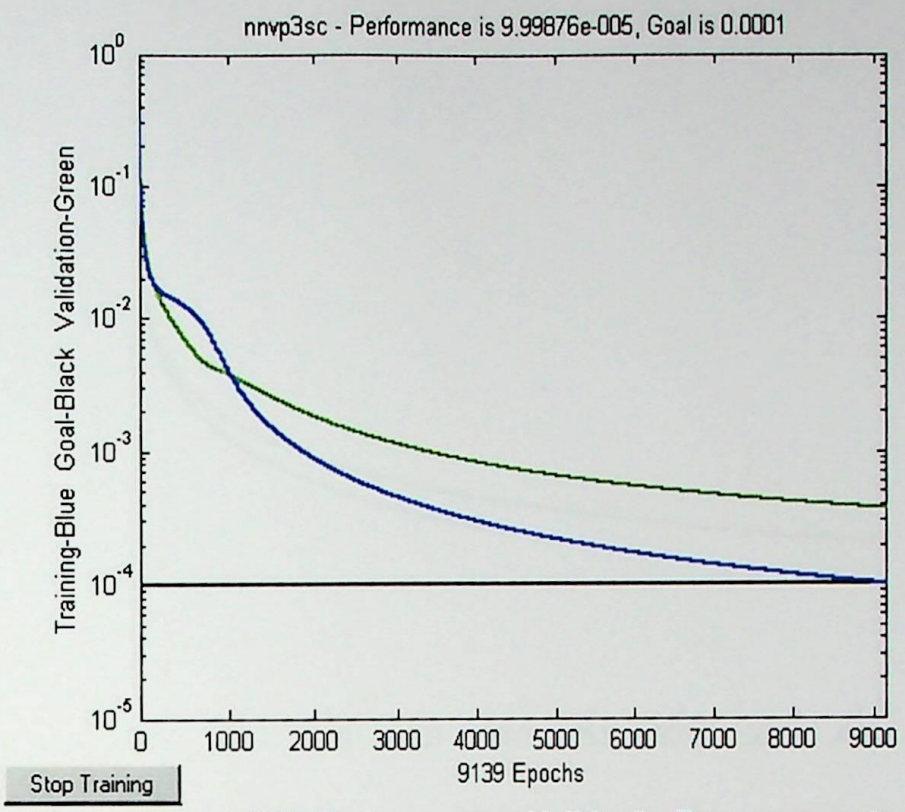


Figura 7.39 - SSE Treinamento e Validação Processamento 4.1.2 NN-SC-32x8x2

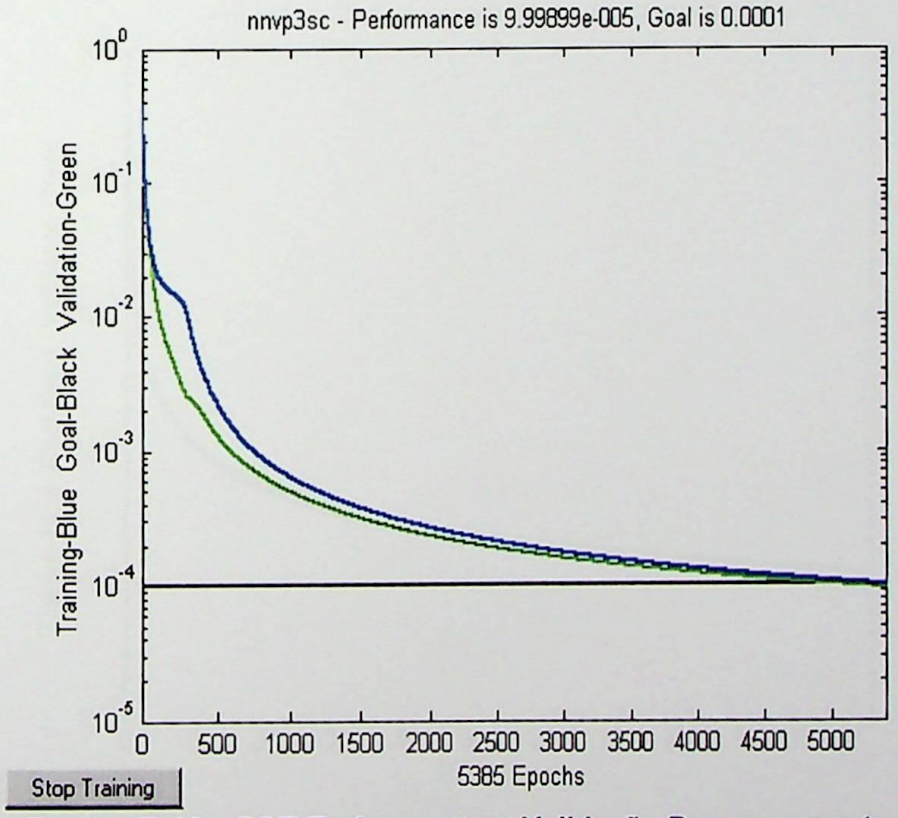


Figura 7.40 - SSE Treinamento e Validação Processamento 4.1.2 NN-SC-32x8x4x2

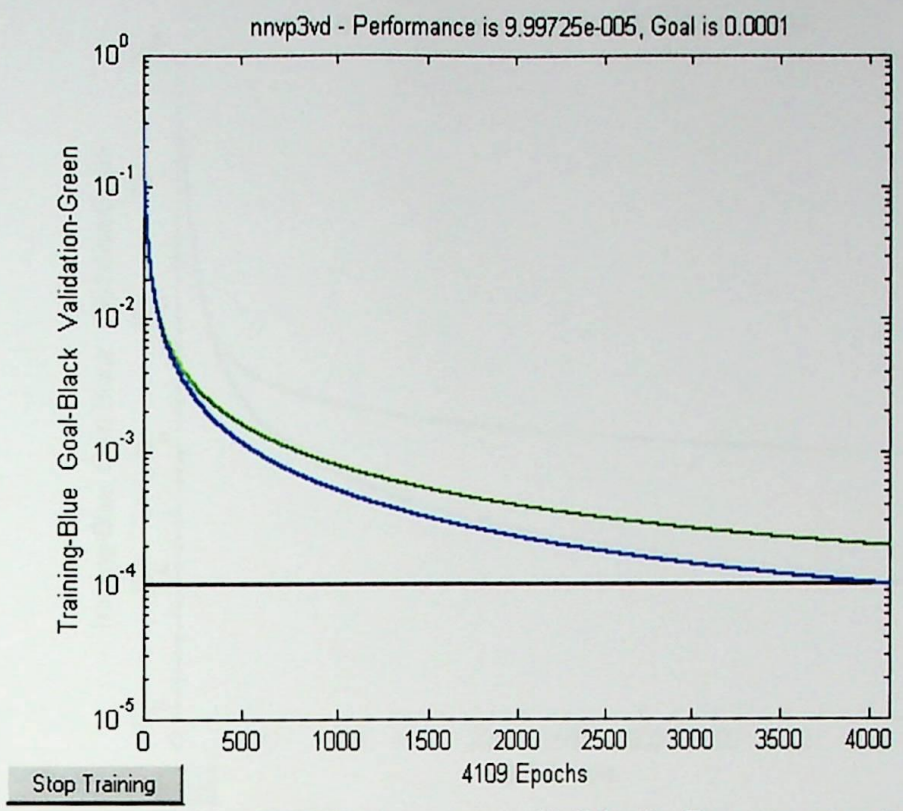


Figura 7.41 - SSE Treinamento e Validação Processamento 4.1.2 NN-VD-32x8x2

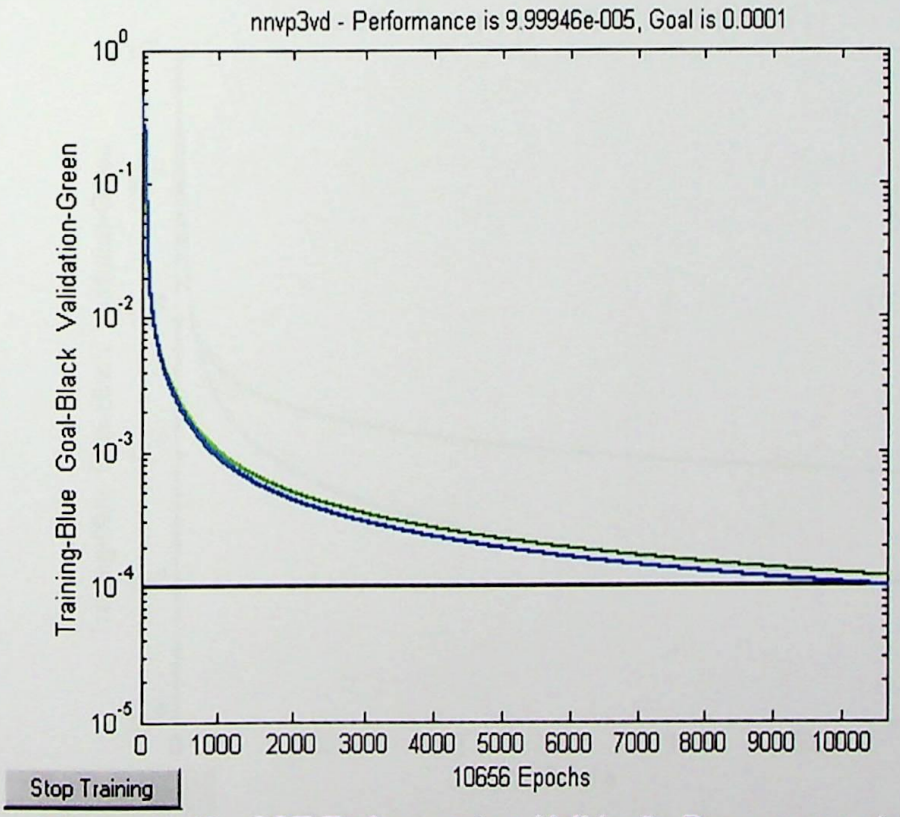


Figura 7.42 - SSE Treinamento e Validação Processamento 4.1.2 NN-VD-32x8x4x2

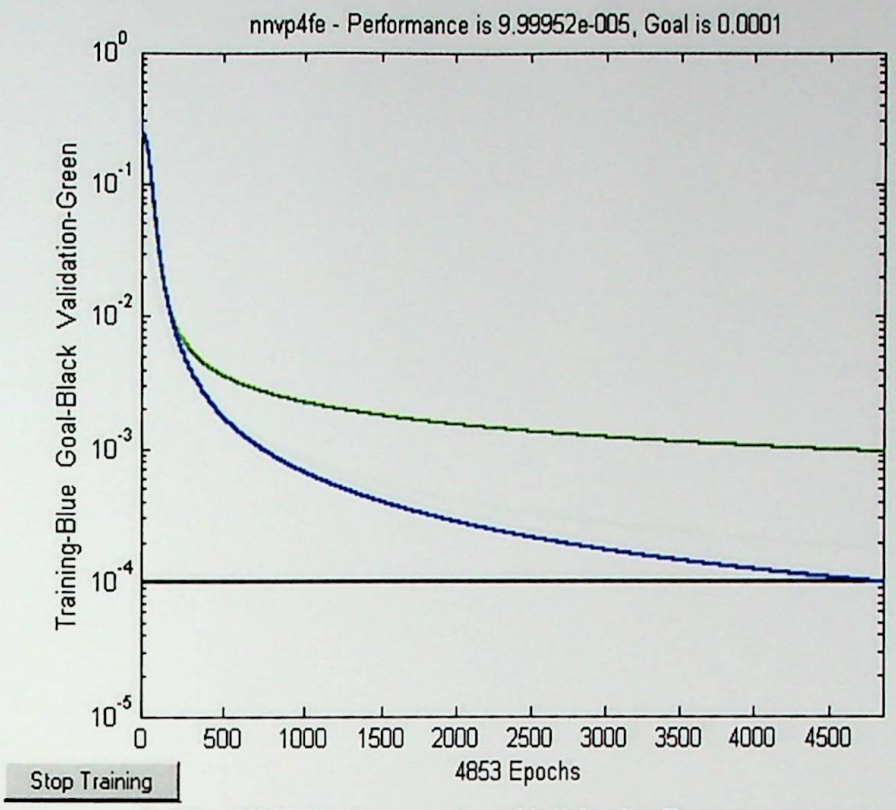


Figura 7.43 - SSE Treinamento e Validação Processamento 4.2 NN-FE-42x8x2

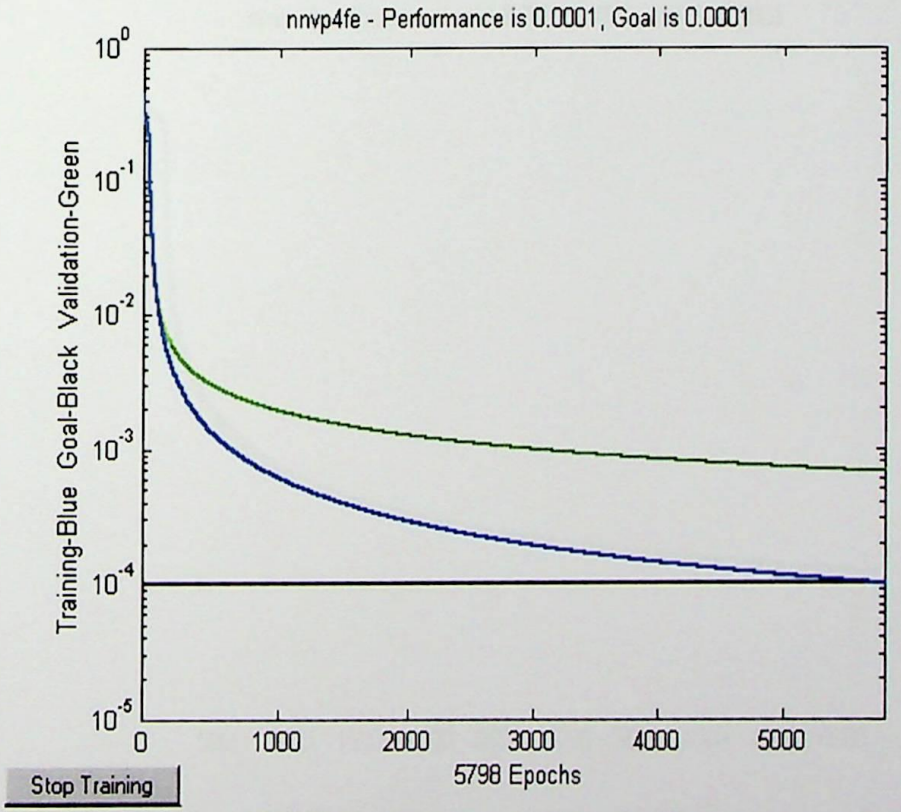


Figura 7.44 - SSE Treinamento e Validação Processamento 4.2 NN-FE-42x8x4x2

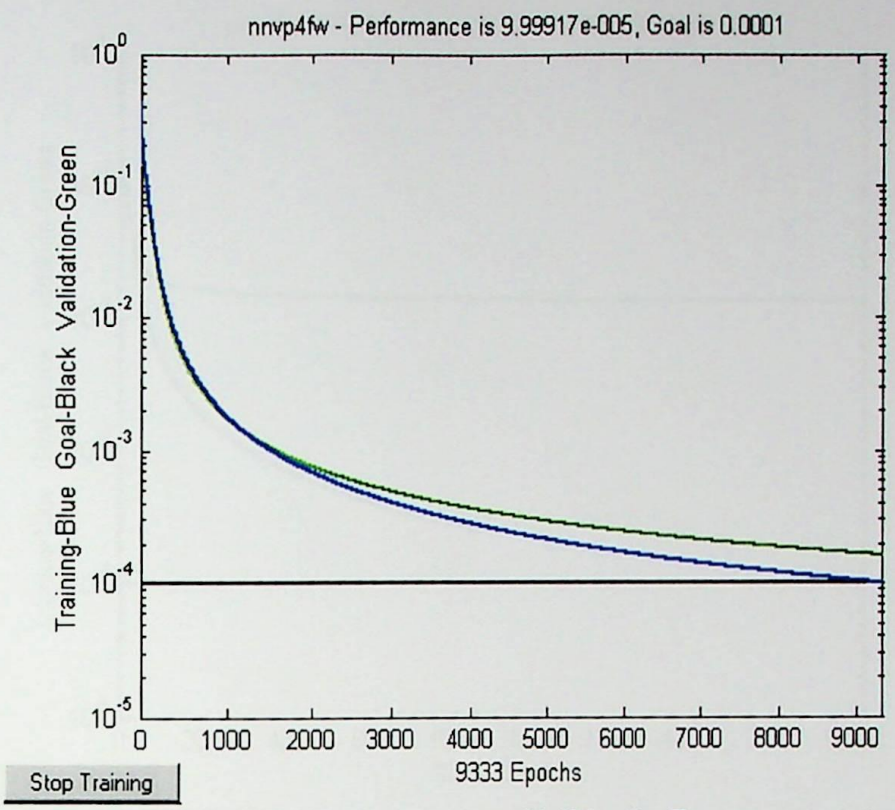


Figura 7.45 - SSE Treinamento e Validação Processamento 4.2 NN-FW-42x8x2

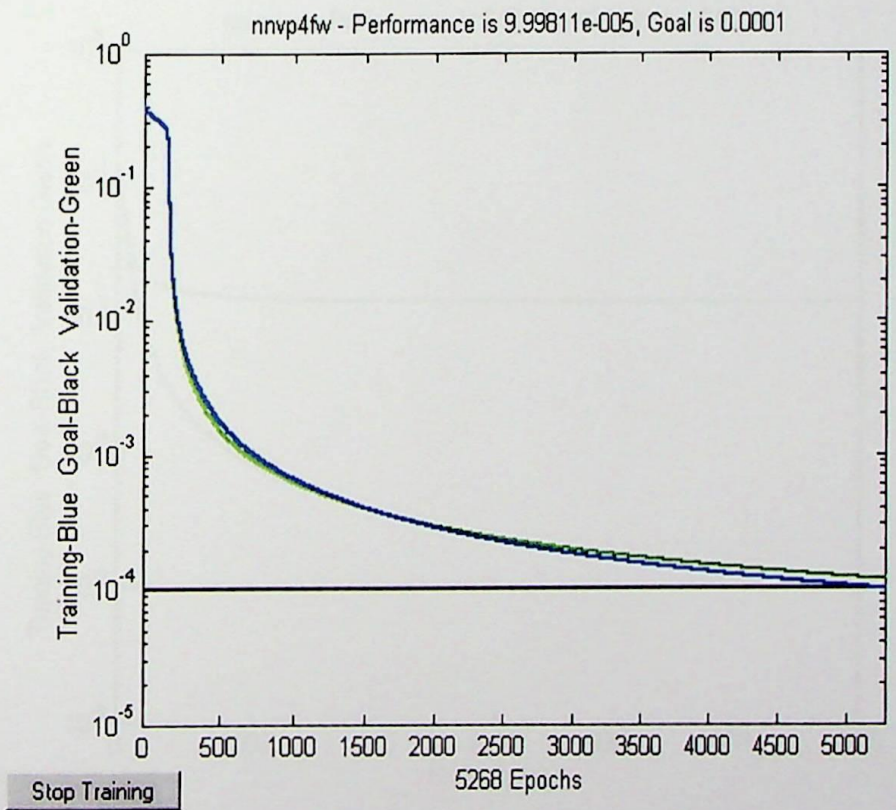


Figura 7.46 - SSE Treinamento e Validação Processamento 4.2 NN-FW-42x8x4x2

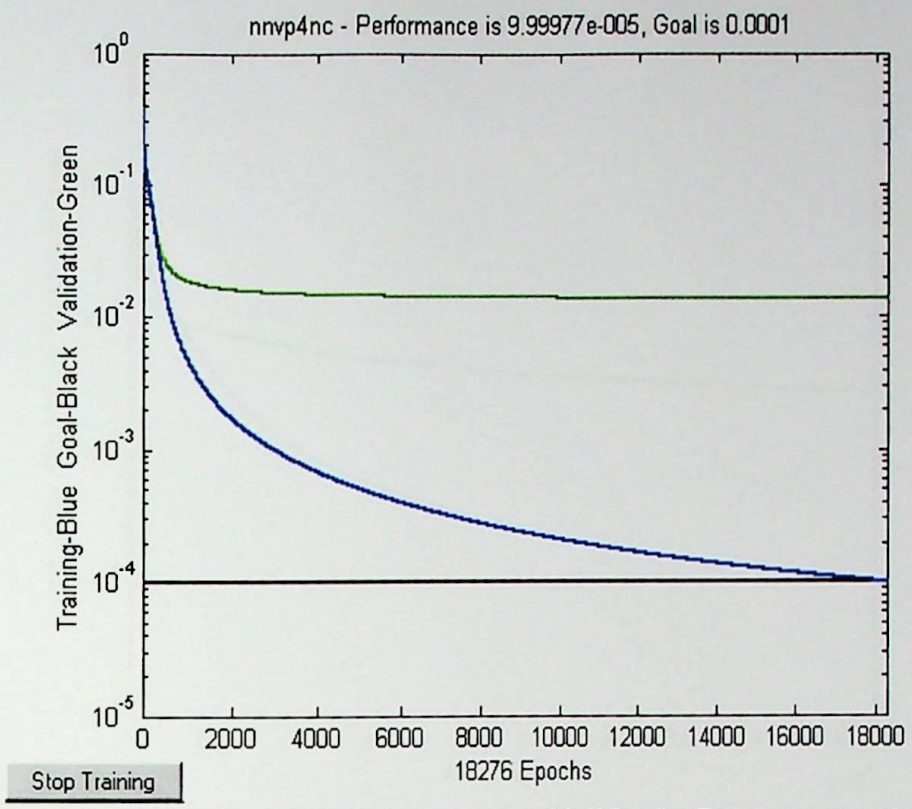


Figura 7.47 - SSE Treinamento e Validação Processamento 4.2 NN-NC-42x8x2

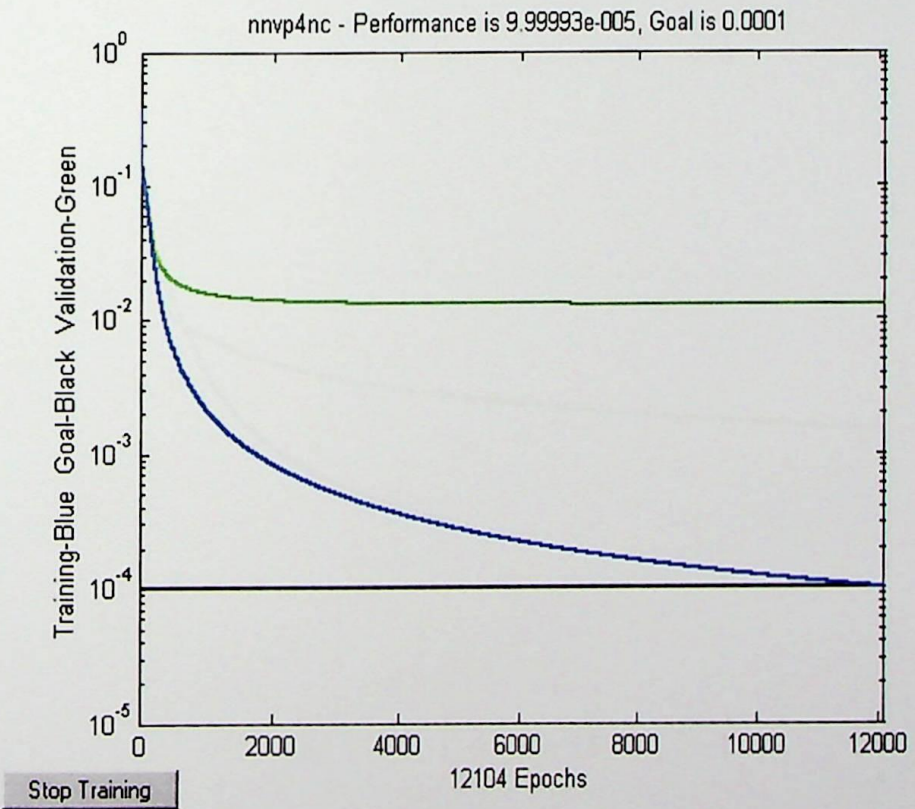


Figura 7.48 - SSE Treinamento e Validação Processamento 4.2 NN-NC-42x8x4x2

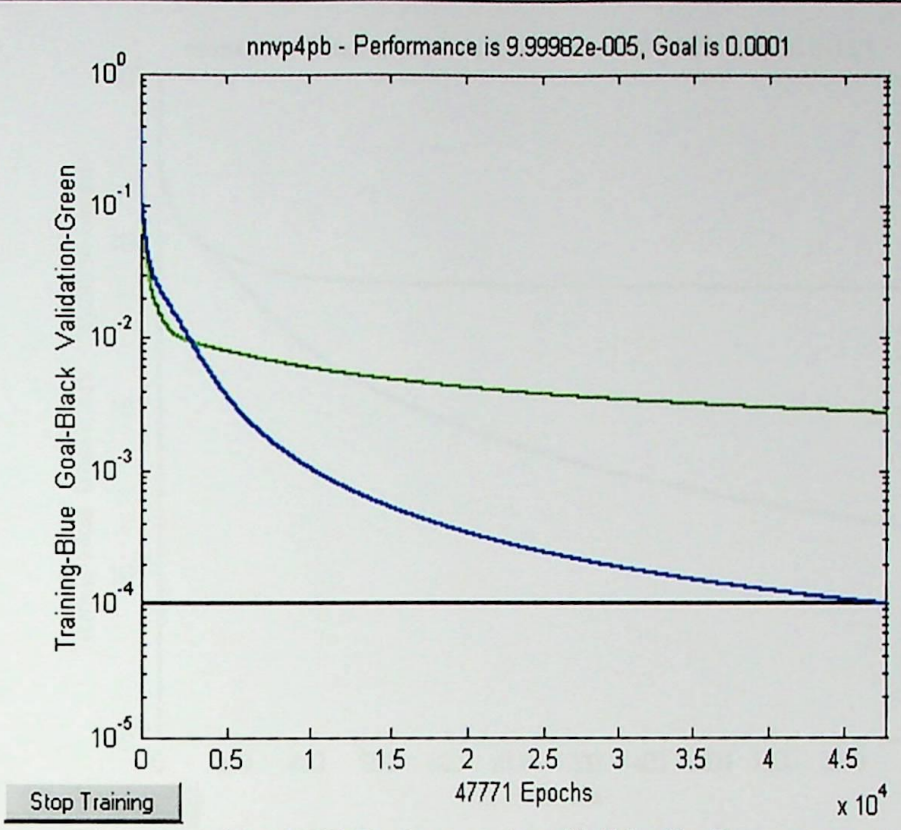


Figura 7.49 - SSE Treinamento e Validação Processamento 4.2 NN-PB-42x8x2

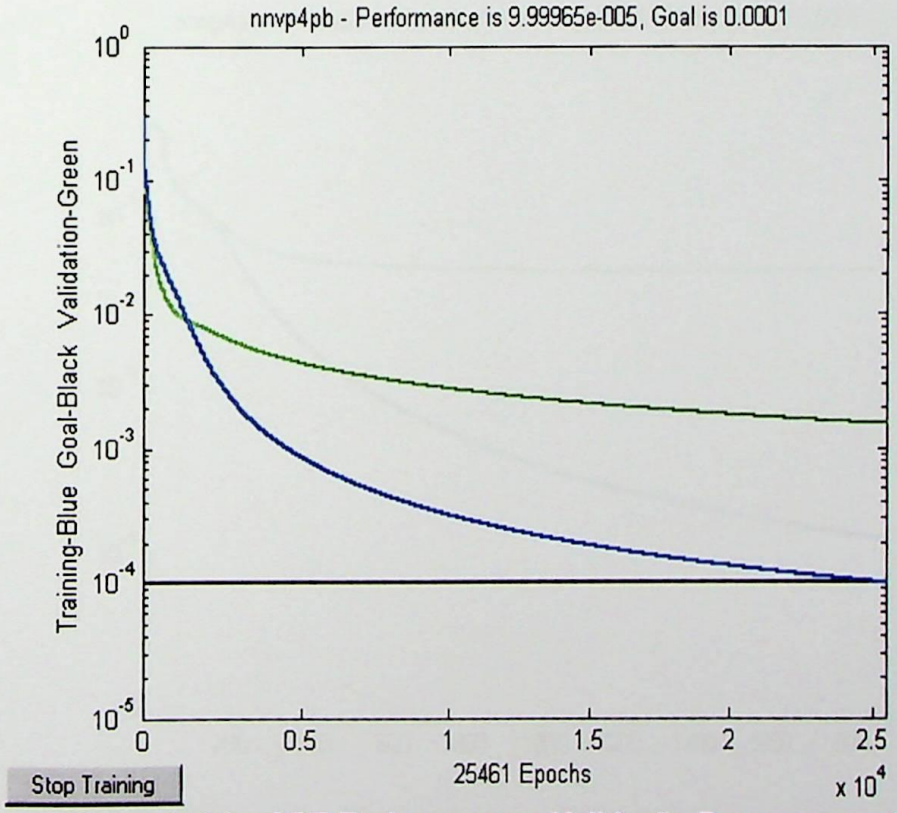


Figura 7.50 - SSE Treinamento e Validação Processamento 4.2 NN-PB-42x8x4x2

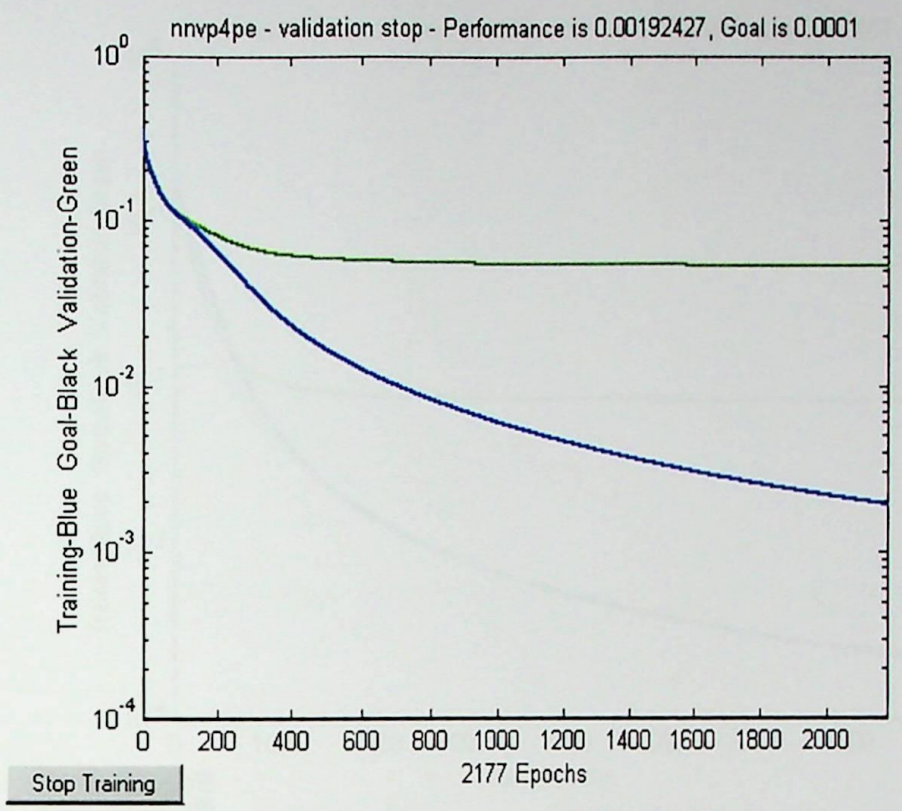


Figura 7.51 - SSE Treinamento e Validação Processamento 4.2 NN-PE-42x8x2

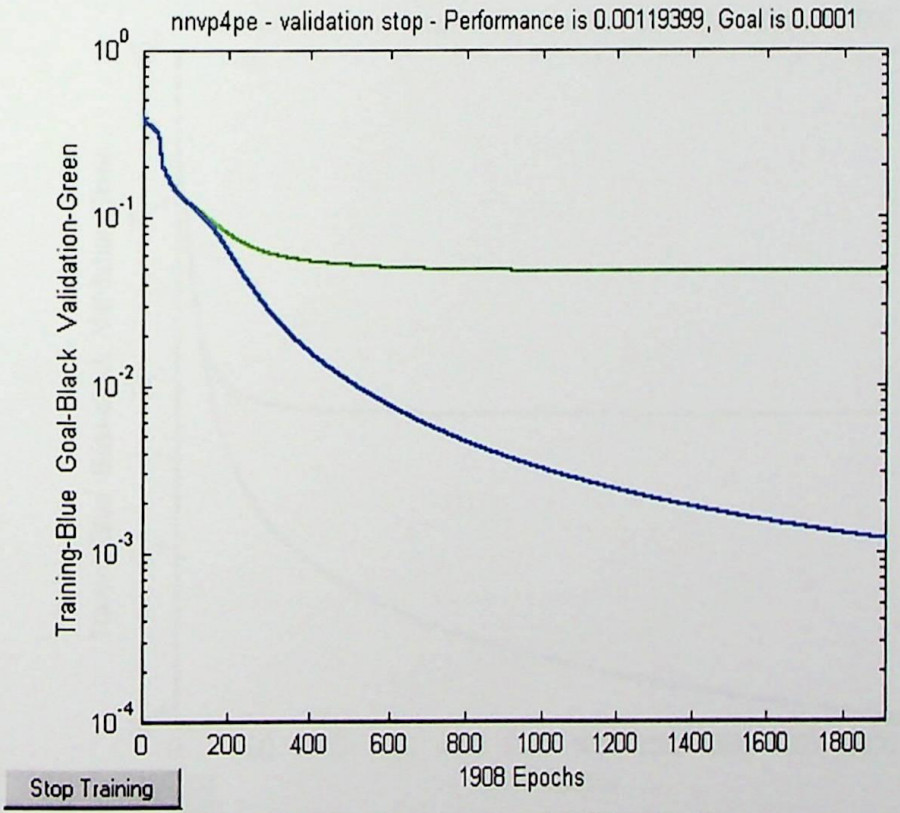


Figura 7.52 - SSE Treinamento e Validação Processamento 4.2 NN-PE-42x8x4x2

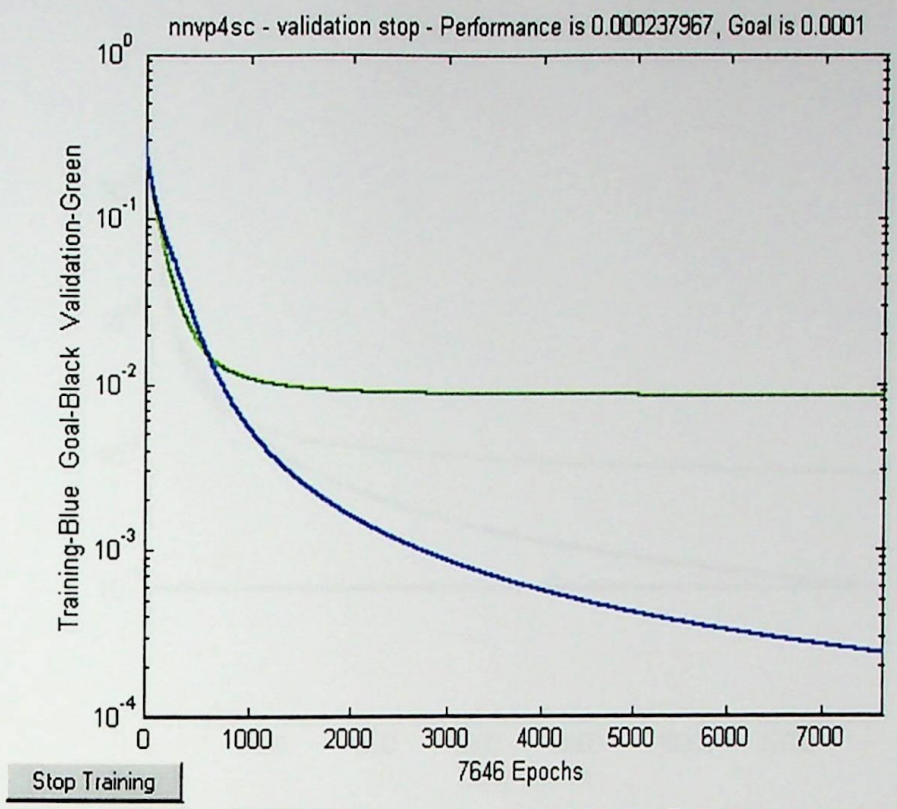


Figura 7.53 - SSE Treinamento e Validação Processamento 4.2 NN-SC-42x8x2

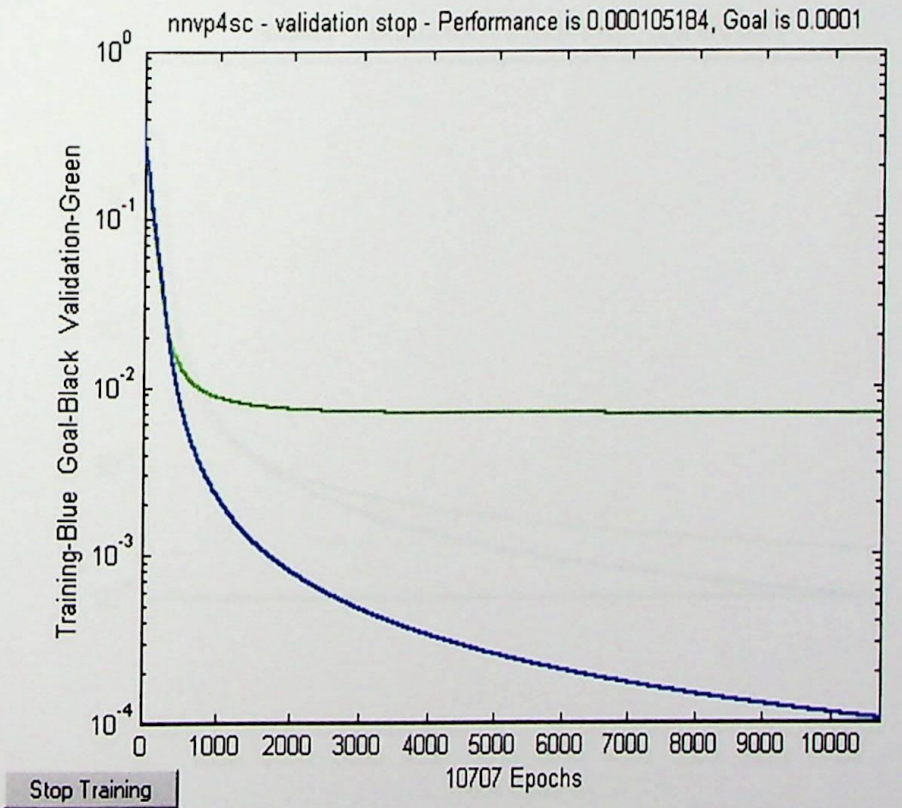


Figura 7.54 - SSE Treinamento e Validação Processamento 4.2 NN-SC-42x8x4x2

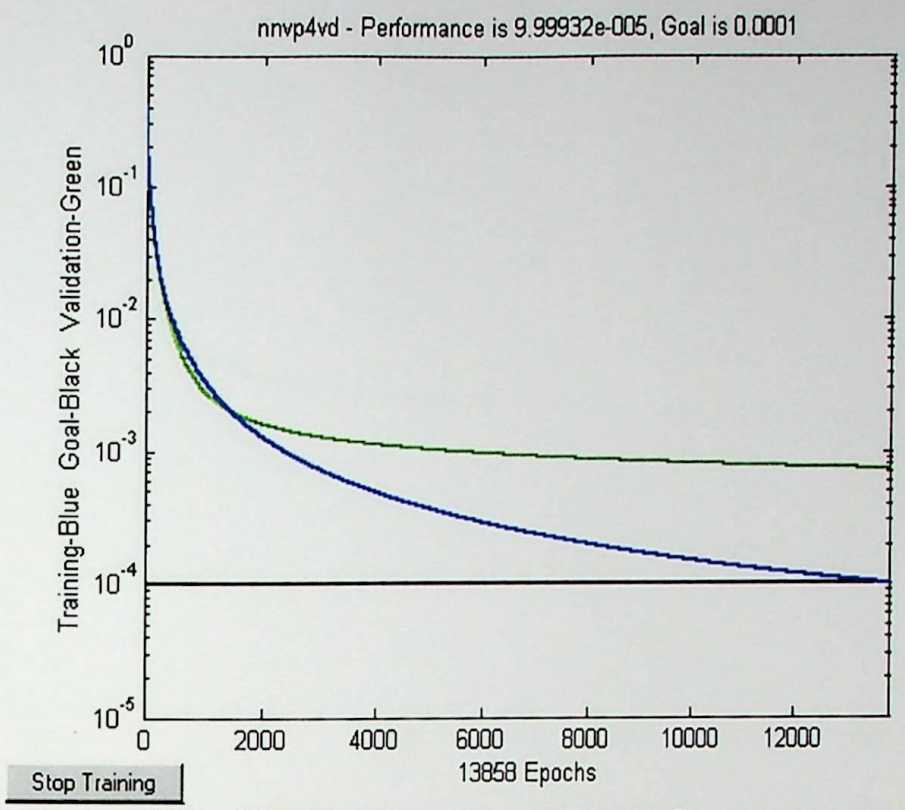


Figura 7.55 - SSE Treinamento e Validação Processamento 4.2 NN-VD-42x8x2

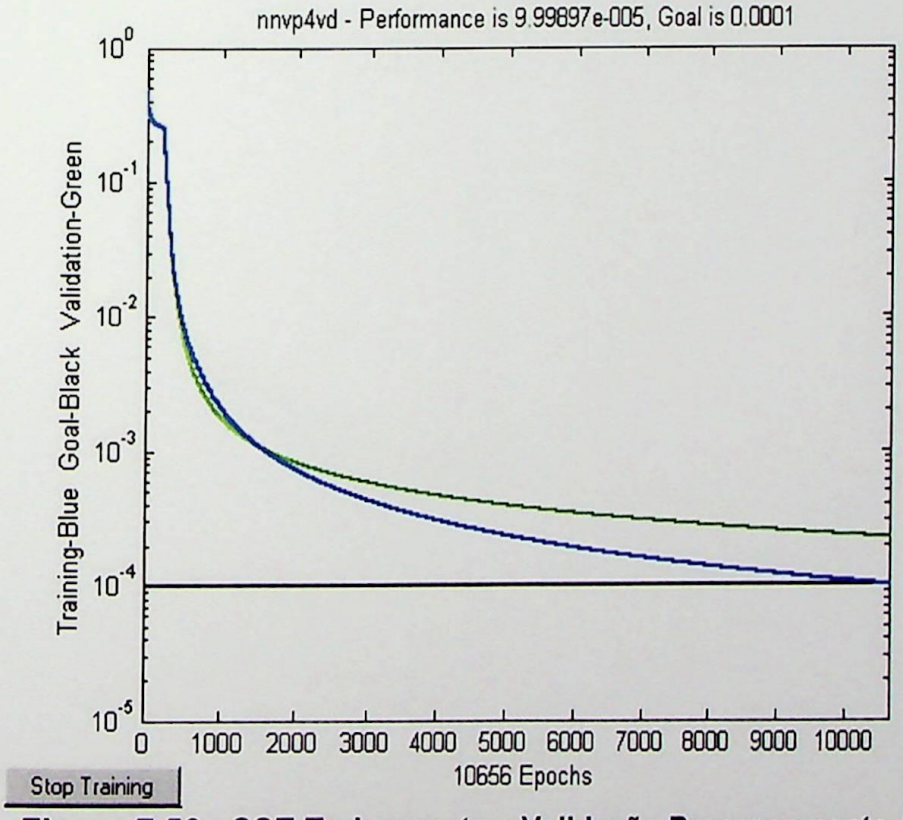


Figura 7.56 - SSE Treinamento e Validação Processamento 4.2 NN-VD-42x8x4x2

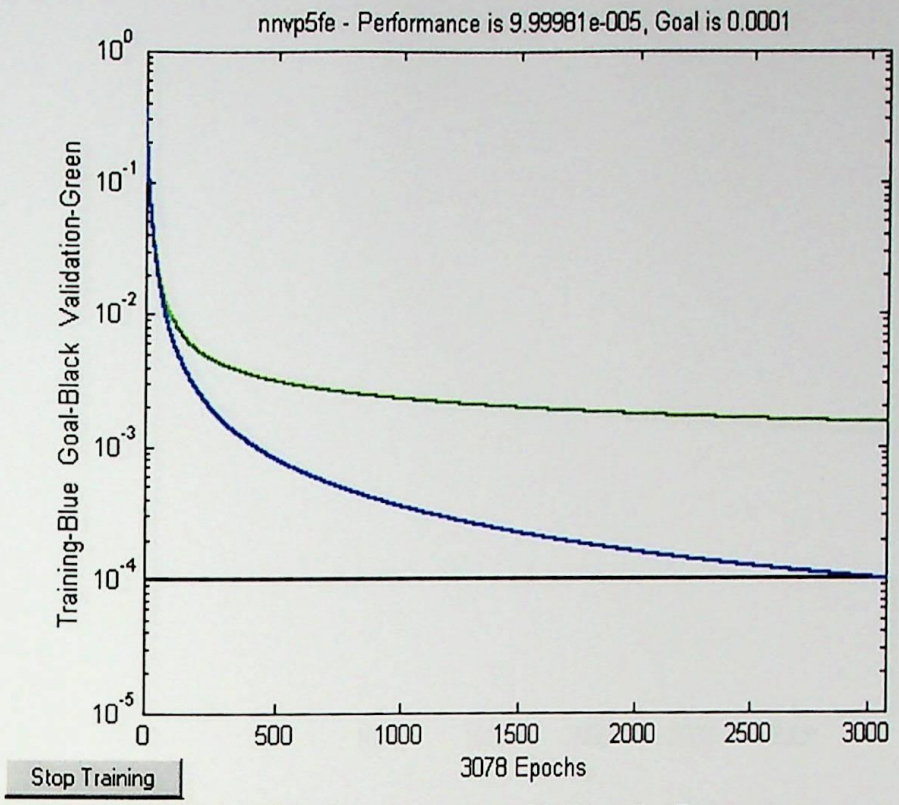


Figura 7.57 - SSE Treinamento e Validação Processamento 4.3 NN-FE-64x8x2

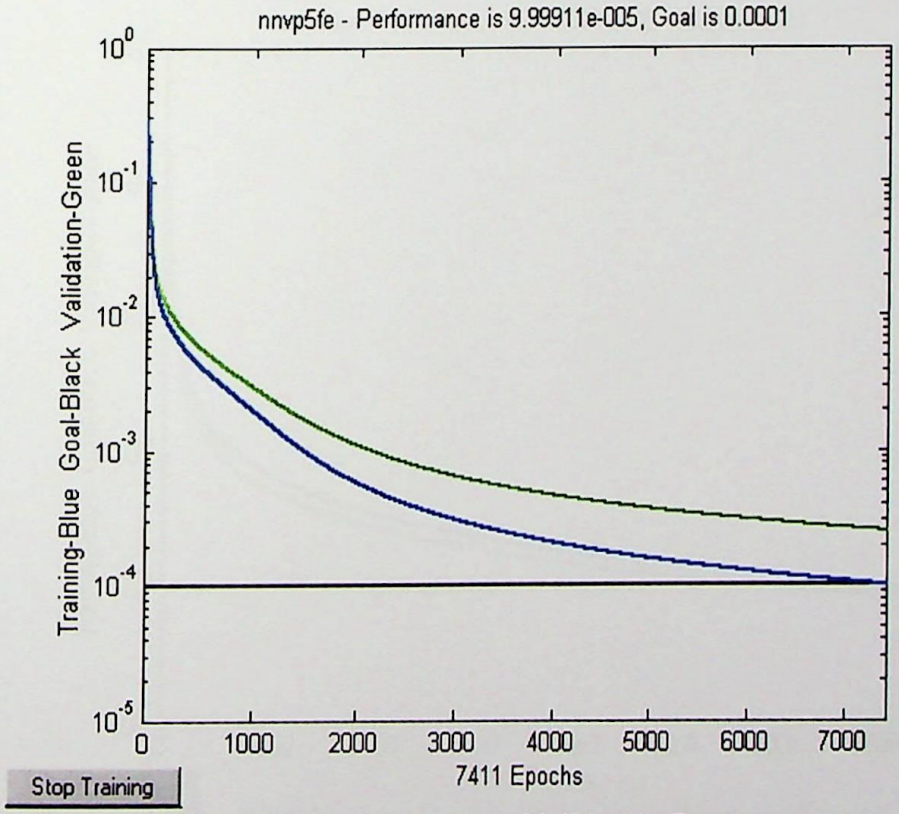


Figura 7.58 - SSE Treinamento e Validação Processamento 4.3 NN-FE-64x8x4x2

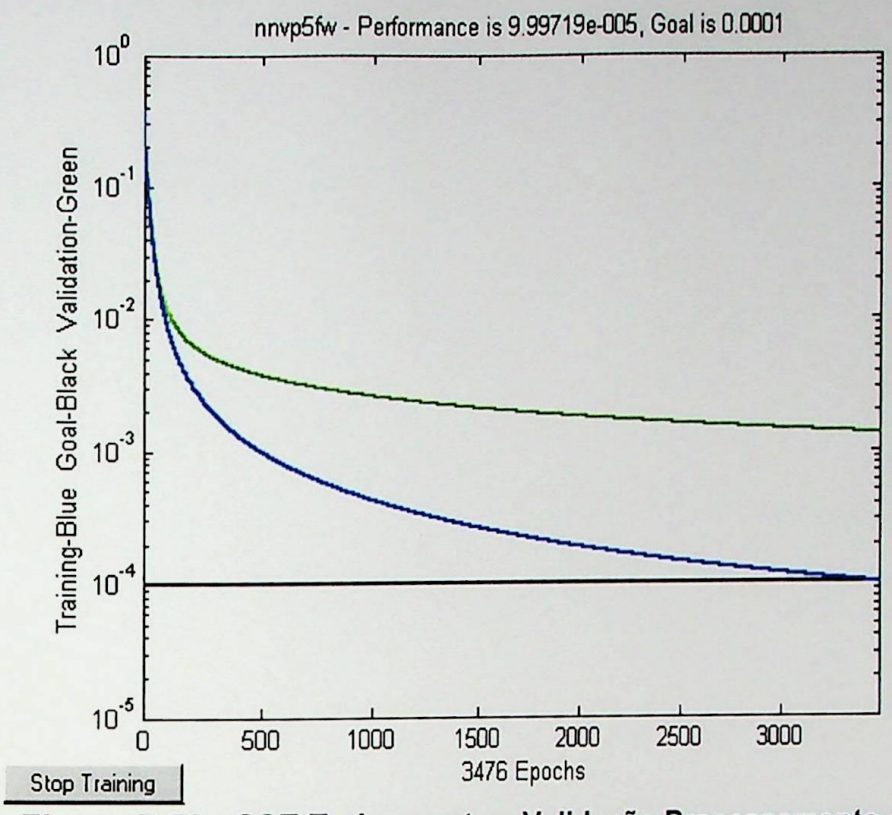


Figura 7.59 - SSE Treinamento e Validação Processamento 4.3 NN-FW-64x8x2

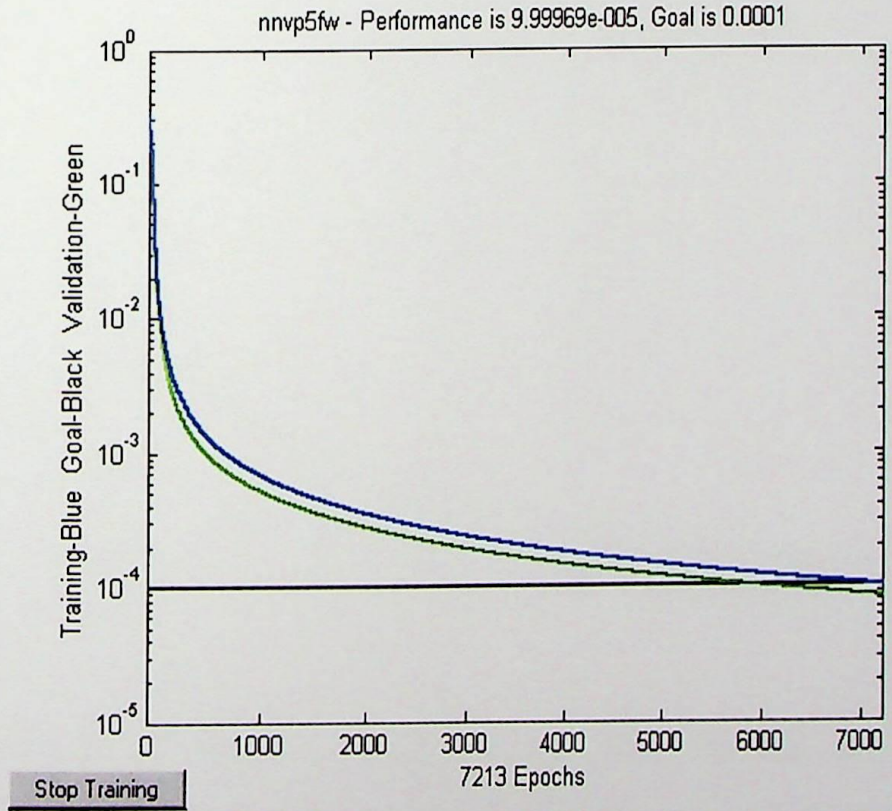


Figura 7.60 - SSE Treinamento e Validação Processamento 4.3 NN-FW-64x8x4x2

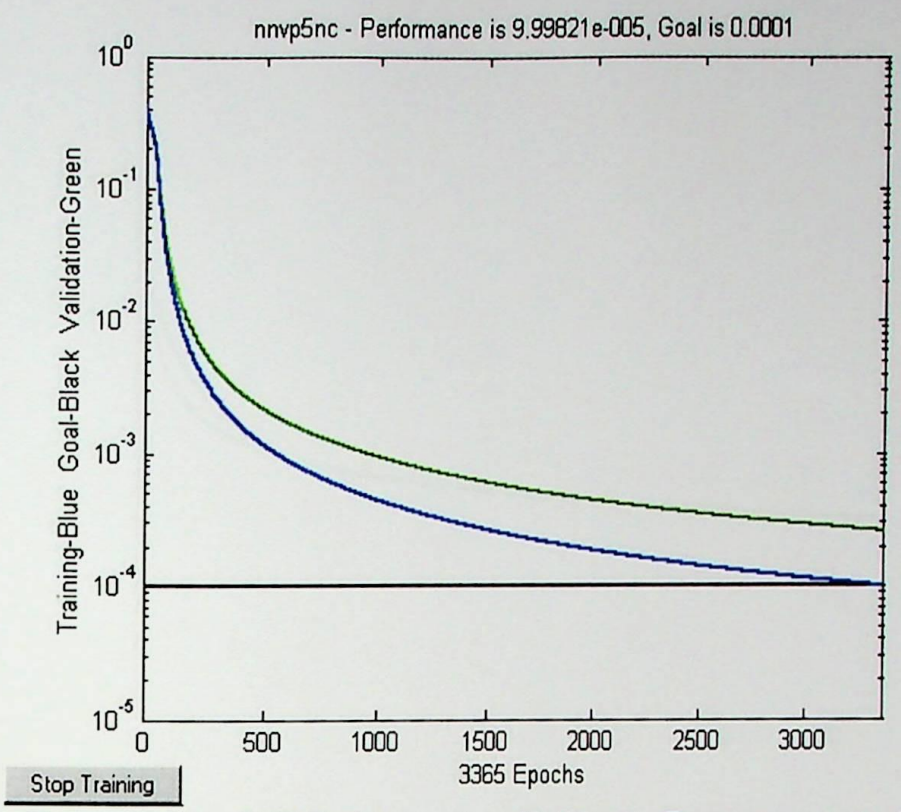


Figura 7.61 - SSE Treinamento e Validação Processamento 4.3 NN-NC-64x8x2

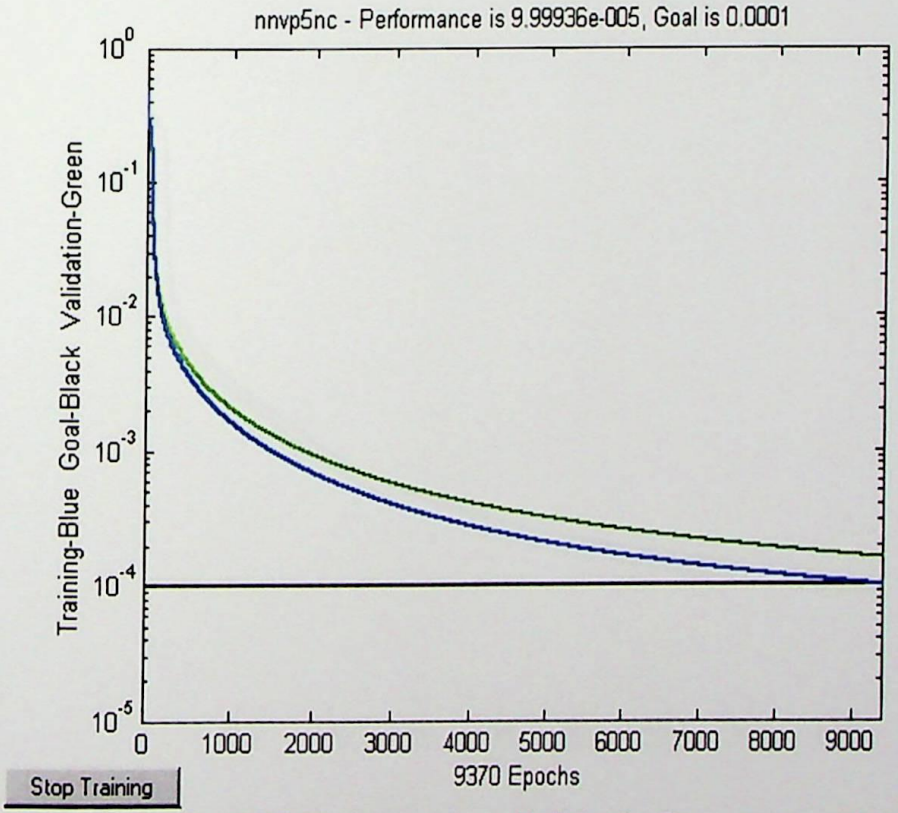


Figura 7.62 - SSE Treinamento e Validação Processamento 4.3 NN-NC-64x8x4x2

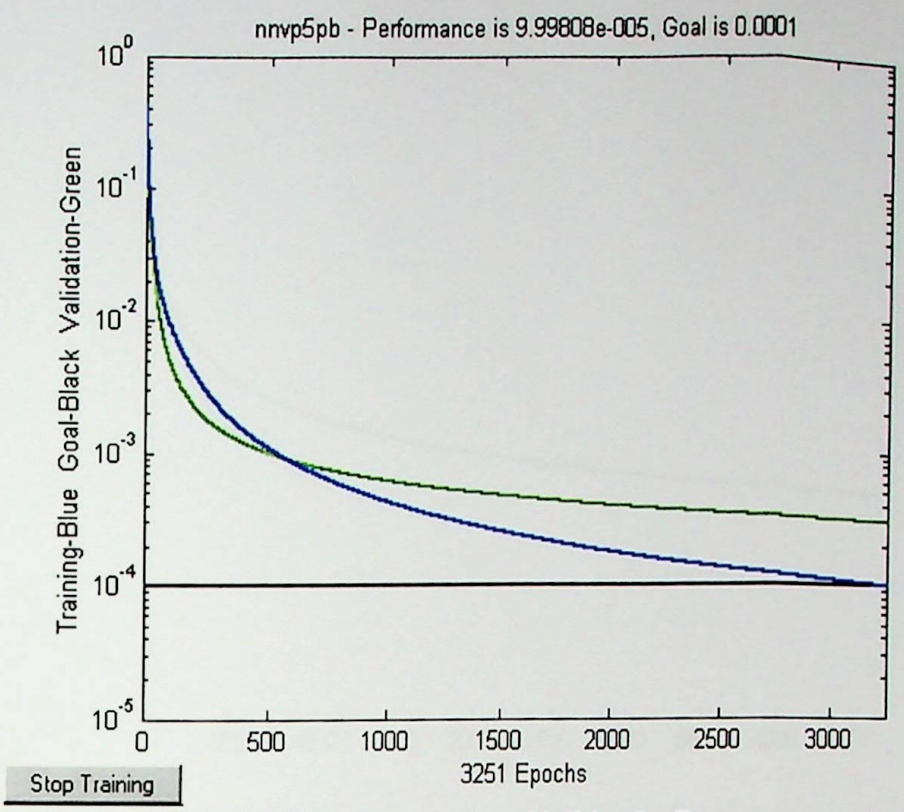


Figura 7.63 - SSE Treinamento e Validação Processamento 4.3 NN-PB-64x8x2

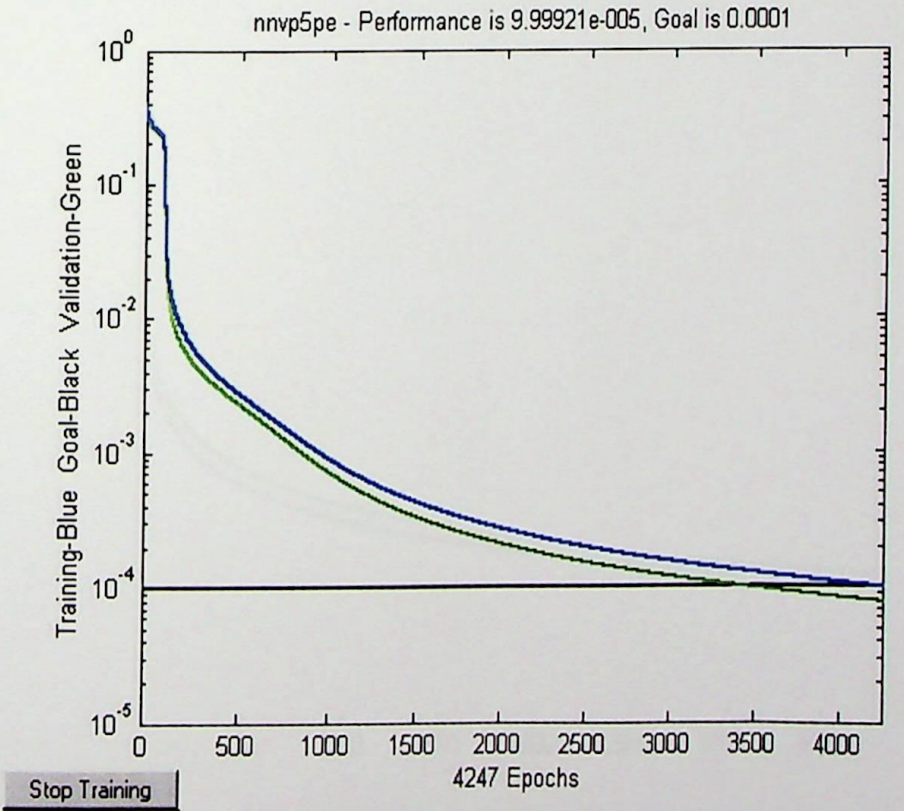


Figura 7.64 - SSE Treinamento e Validação Processamento 4.3 NN-PB-64x8x4x2

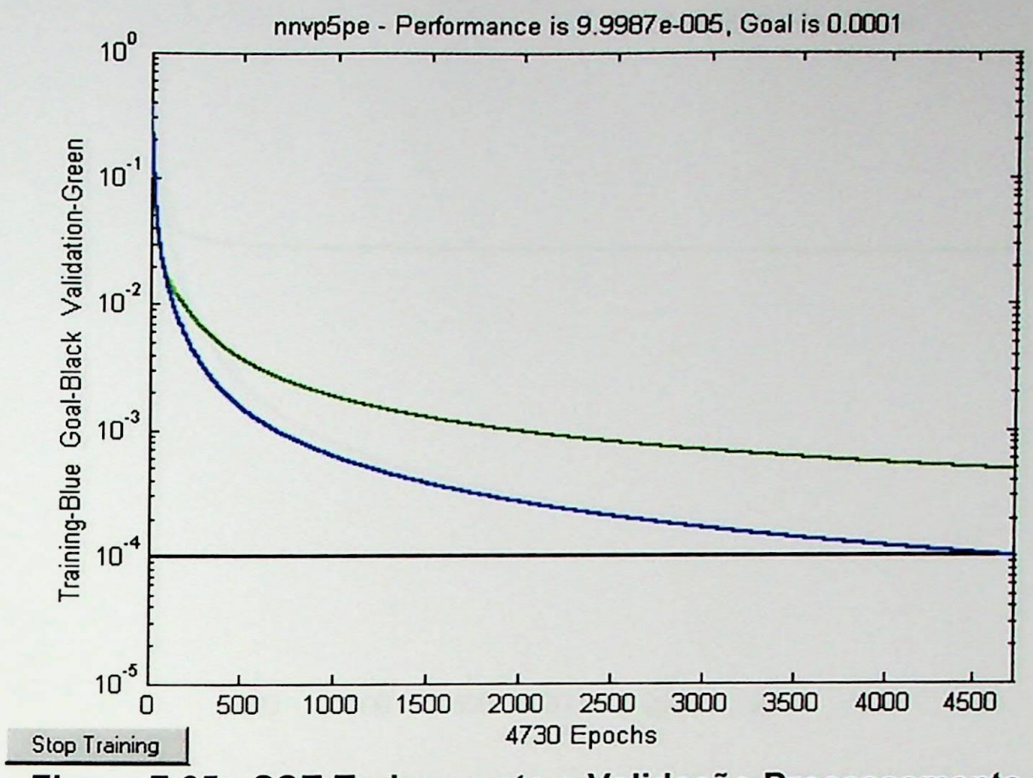


Figura 7.65 - SSE Treinamento e Validação Processamento 4.3 NN-PE-64x8x2

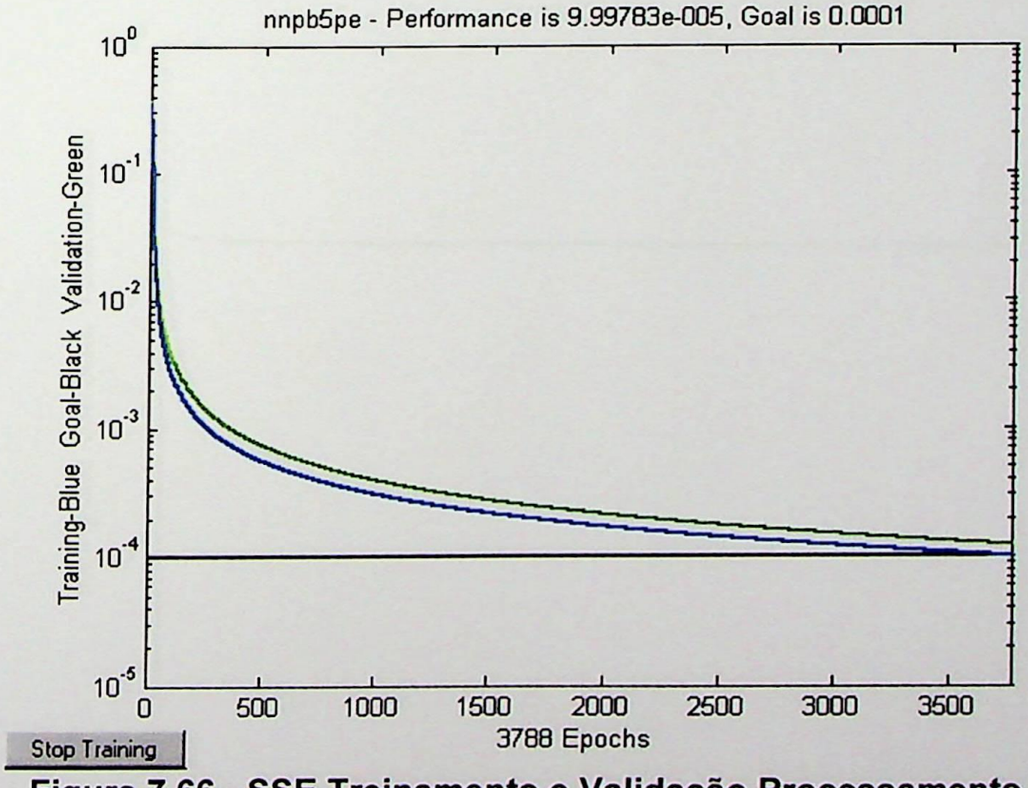


Figura 7.66 - SSE Treinamento e Validação Processamento 4.3 NN-PE-64x8x4x2

UNIVERSIDADE FEDERAL DE ITAIUBA
Biblioteca
UNIFEI

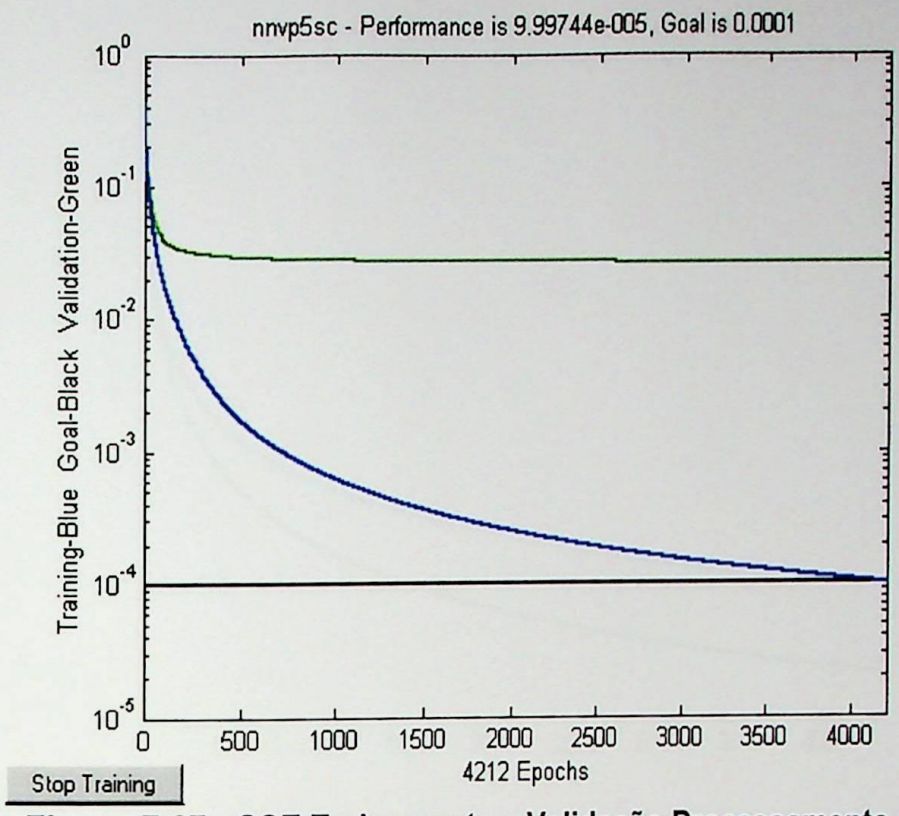


Figura 7.67 - SSE Treinamento e Validação Processamento 4.3 NN-SC-64x8x2

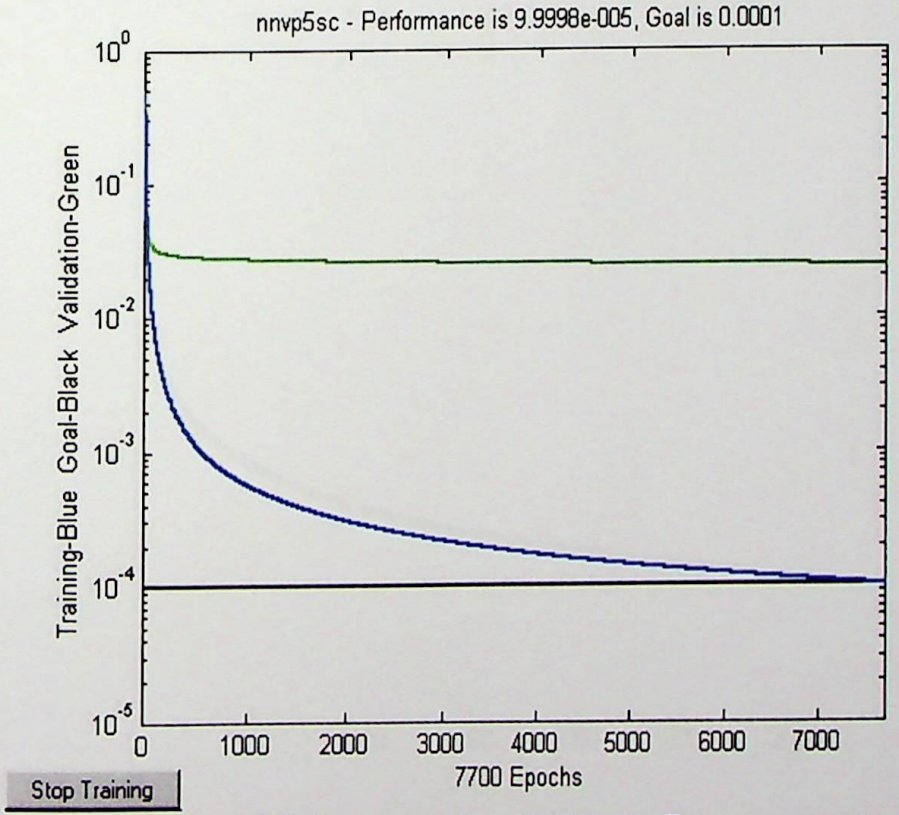


Figura 7.68 - SSE Treinamento e Validação Processamento 4.3 NN-SC-64x8x4x2

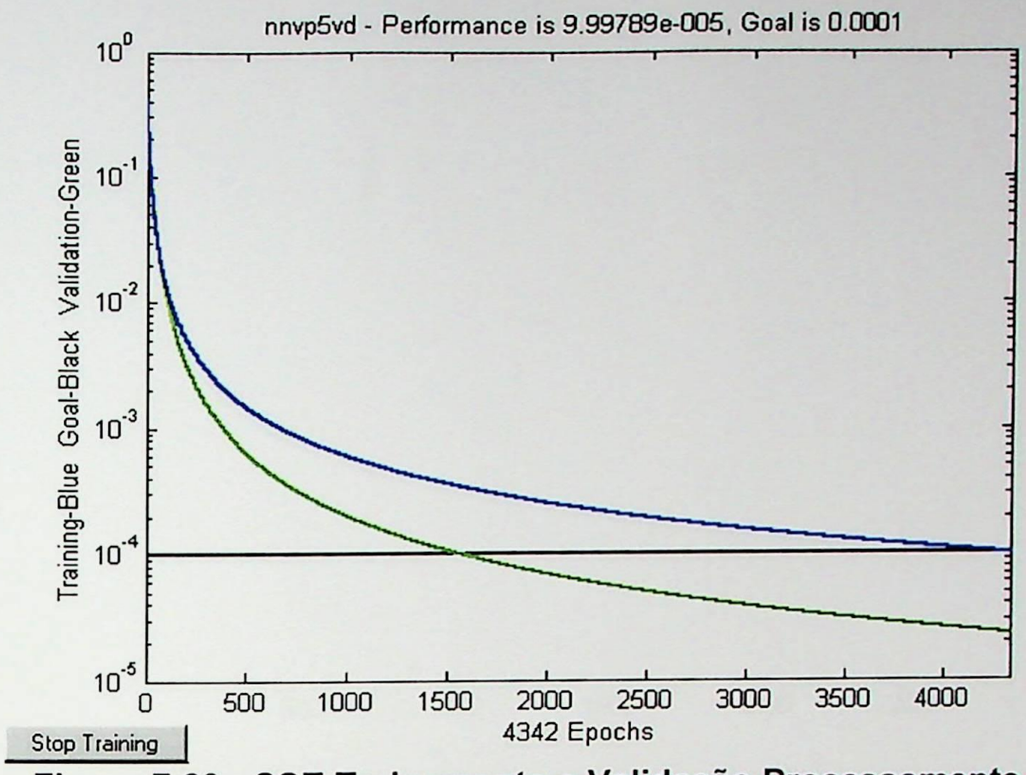


Figura 7.69 - SSE Treinamento e Validação Processamento 4.3 NN-VD-64x8x2

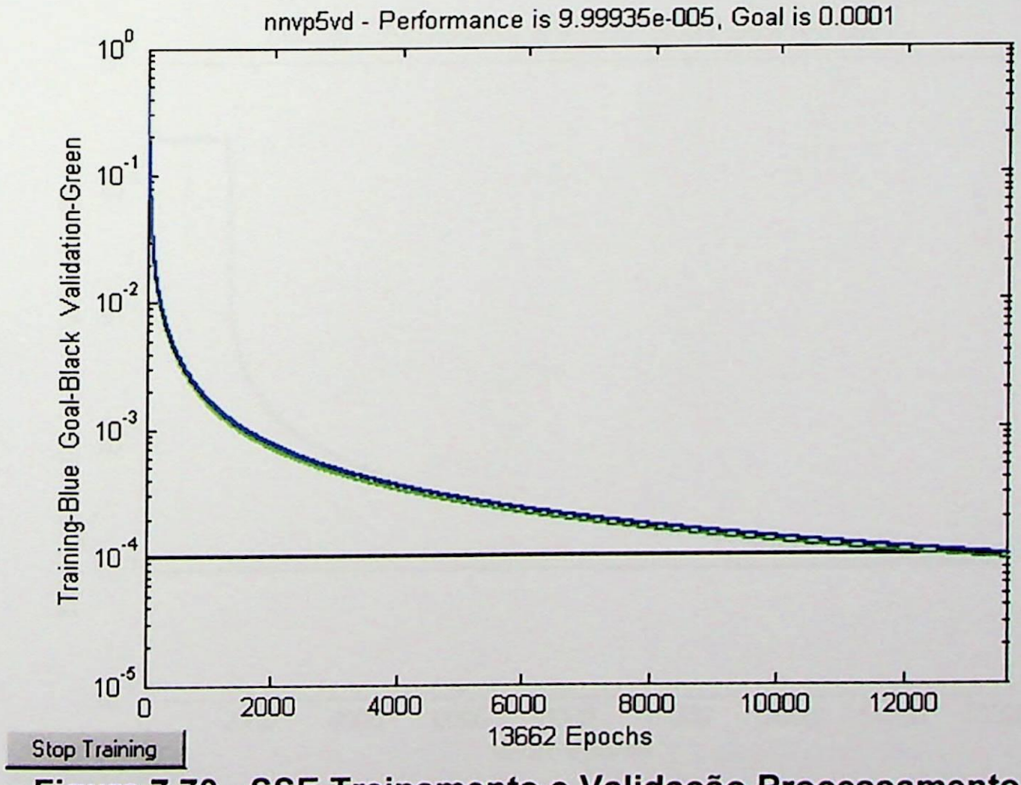


Figura 7.70 - SSE Treinamento e Validação Processamento 4.3 NN-VD-64x8x4x2

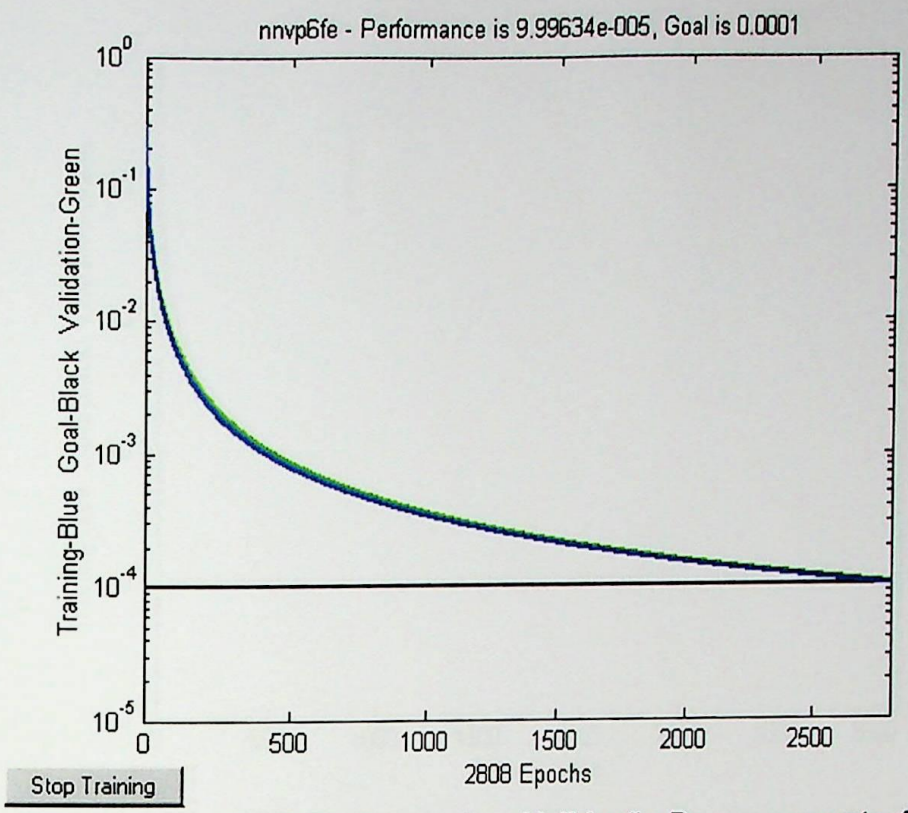


Figura 7.71 - SSE Treinamento e Validação Processamento 4.3.1 NN-FE-32x8x2

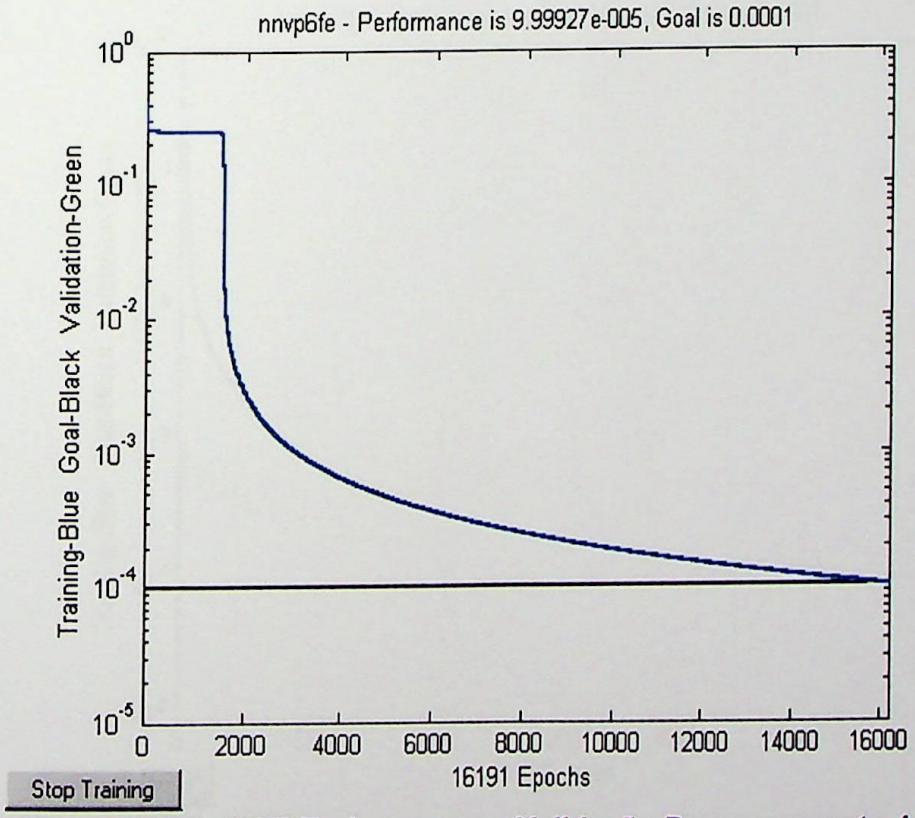


Figura 7.72 - SSE Treinamento e Validação Processamento 4.3.1 NN-FE-32x8x4x2

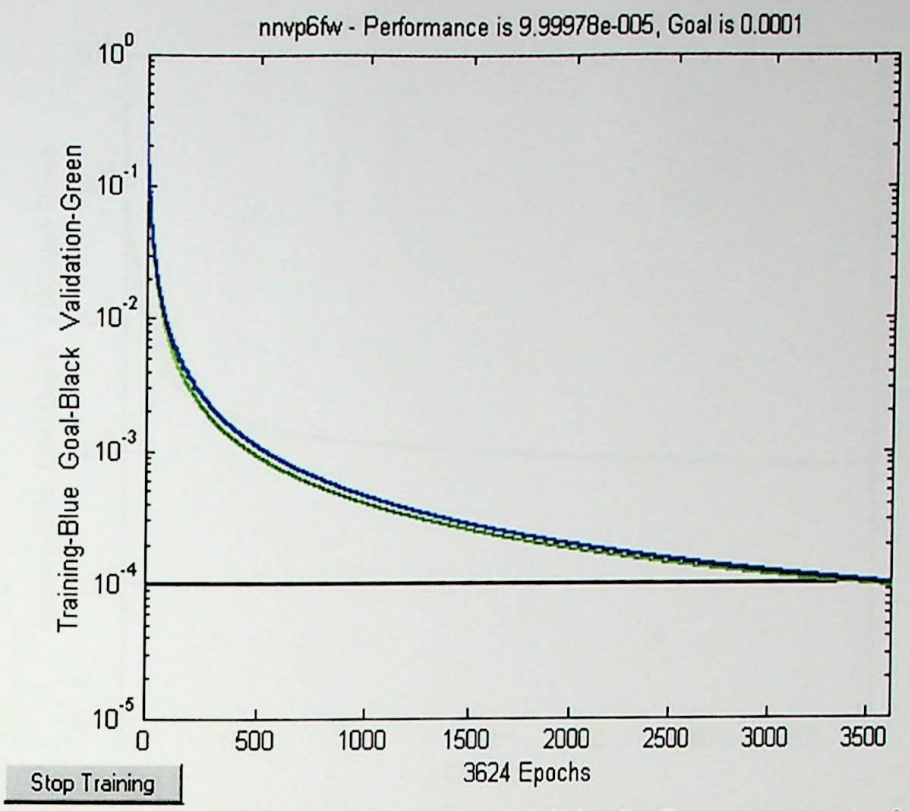


Figura 7.73 - SSE Treinamento e Validação Processamento 4.3.1 NN-FW-32x8x2

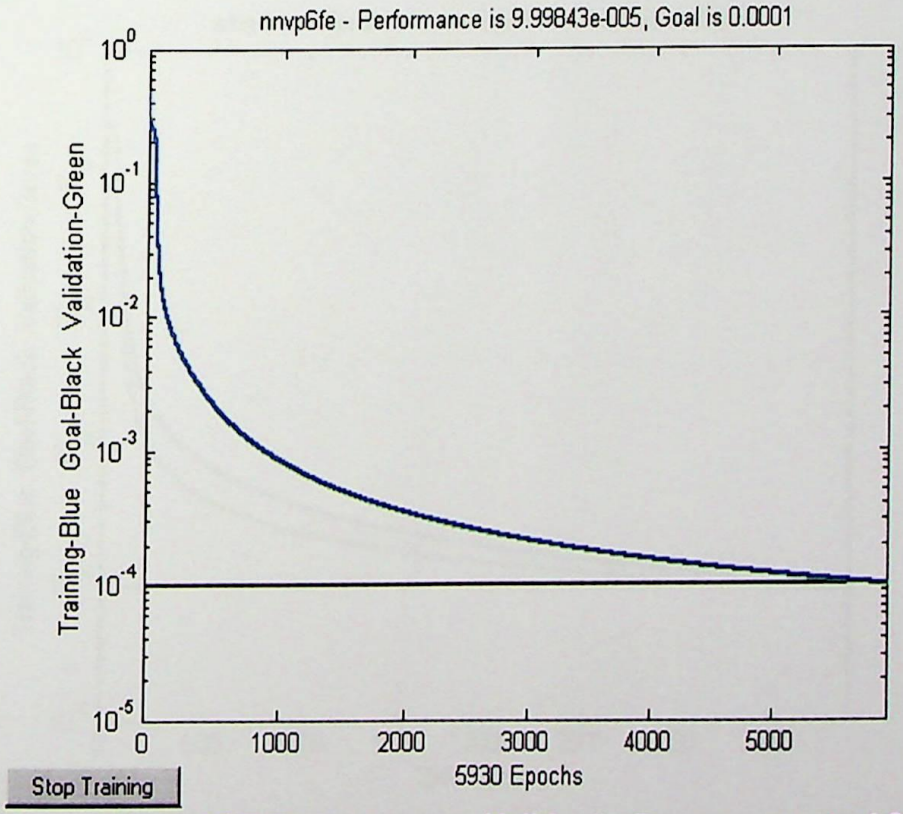


Figura 7.74 - SSE Treinamento e Validação Processamento 4.3.1 NN-FW-32x8x4x2

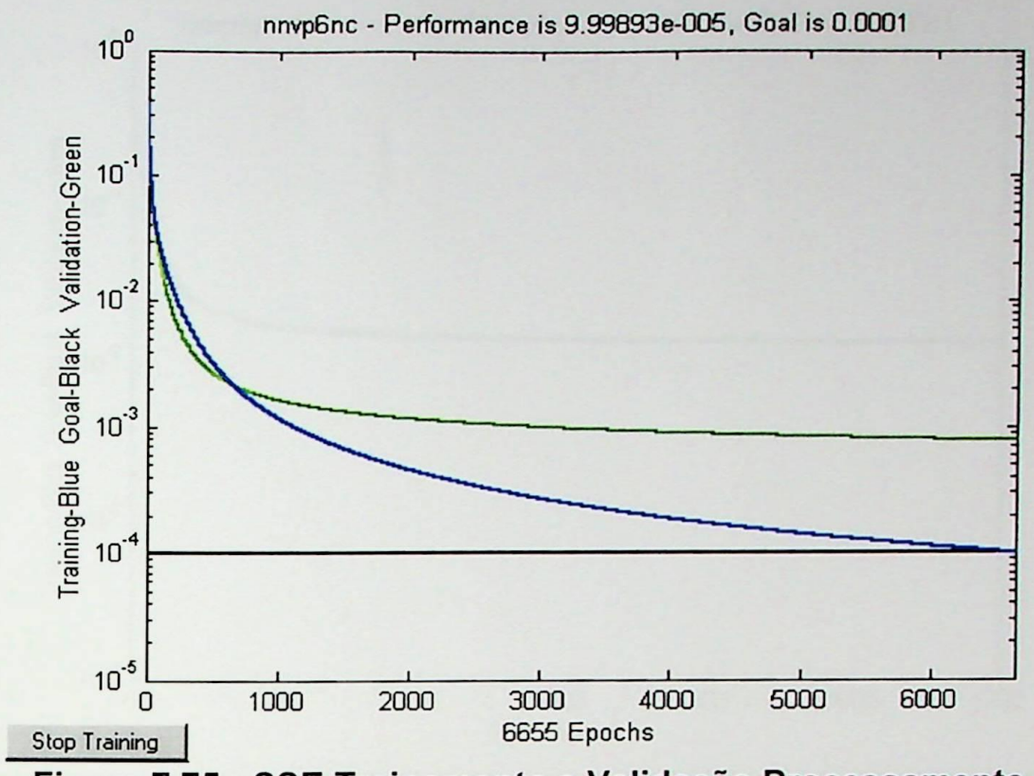


Figura 7.75 - SSE Treinamento e Validação Processamento 4.3.1 NN-NC-32x8x2

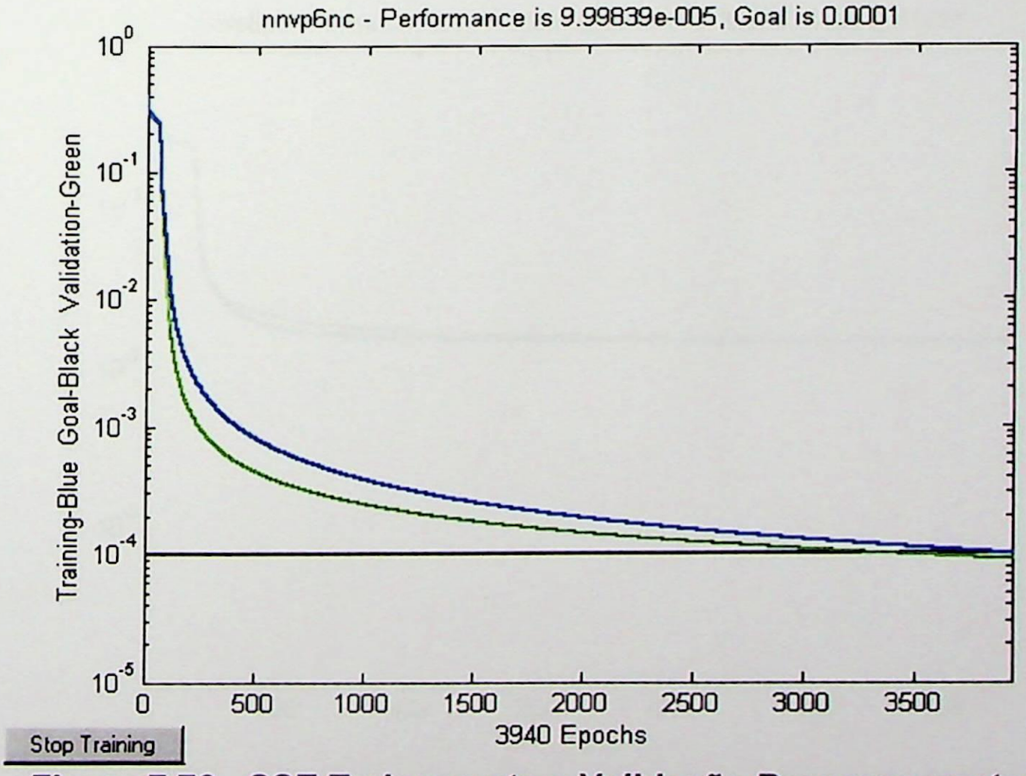


Figura 7.76 - SSE Treinamento e Validação Processamento 4.3.1 NN-NC-32x8x4x2

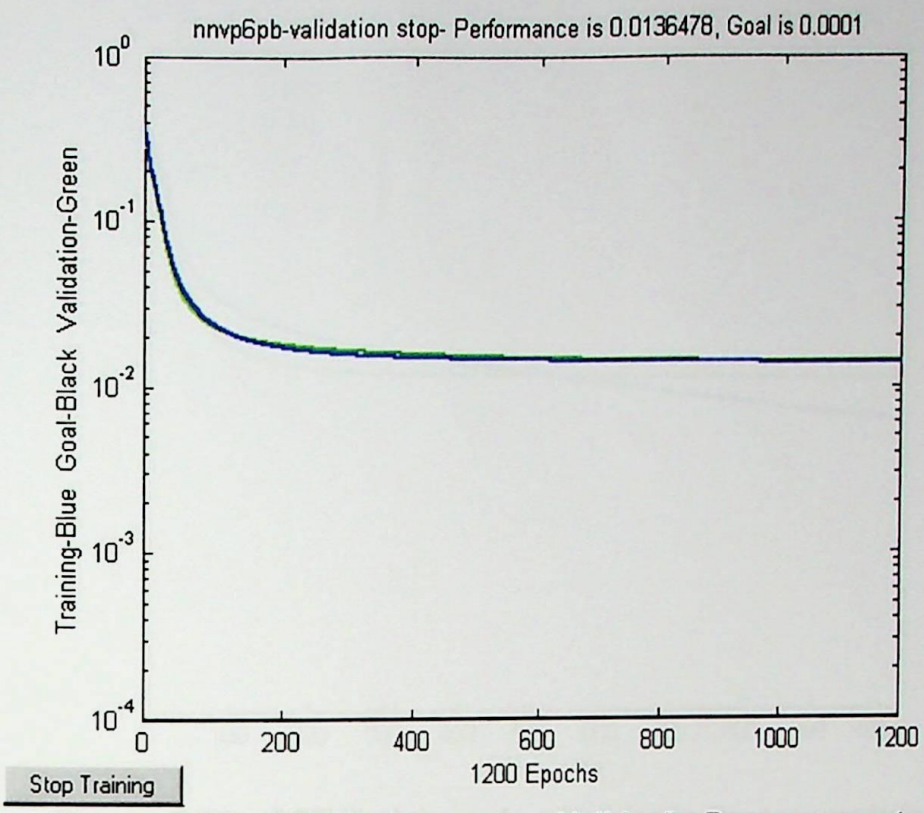


Figura 7.77 - SSE Treinamento e Validação Processamento 4.3.1 NN-PB-32x8x2

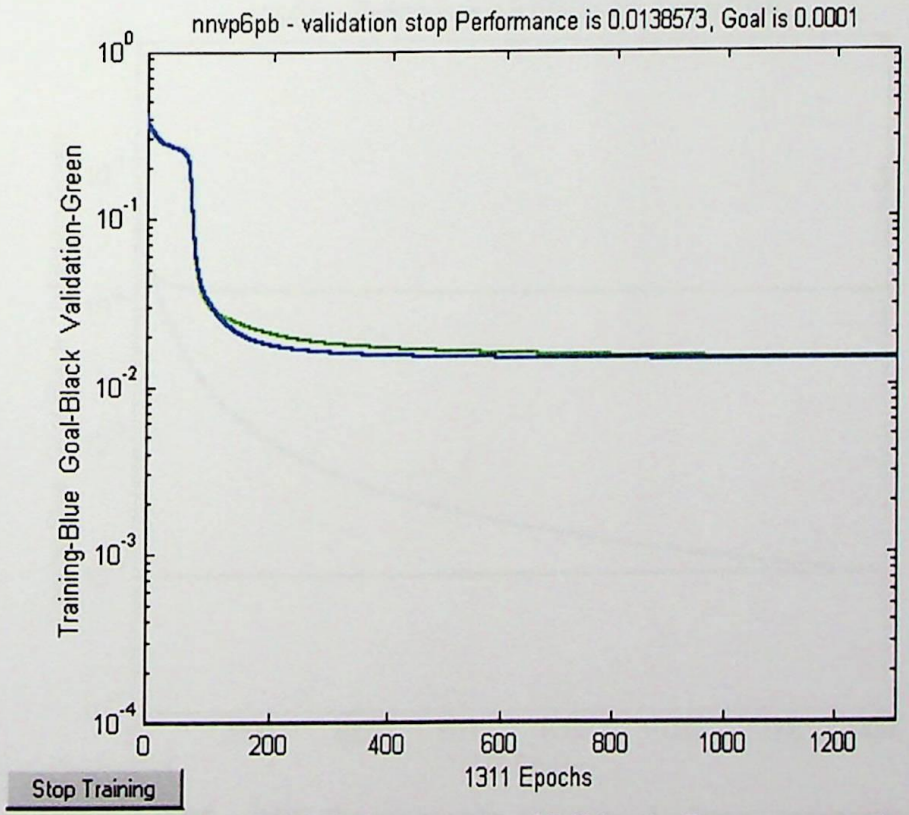


Figura 7.78 - SSE Treinamento e Validação Processamento 4.3.1 NN-PB-32x8x4x2

UNIVERSIDADE FEDERAL DE ITAJUBÁ
UNIFEI

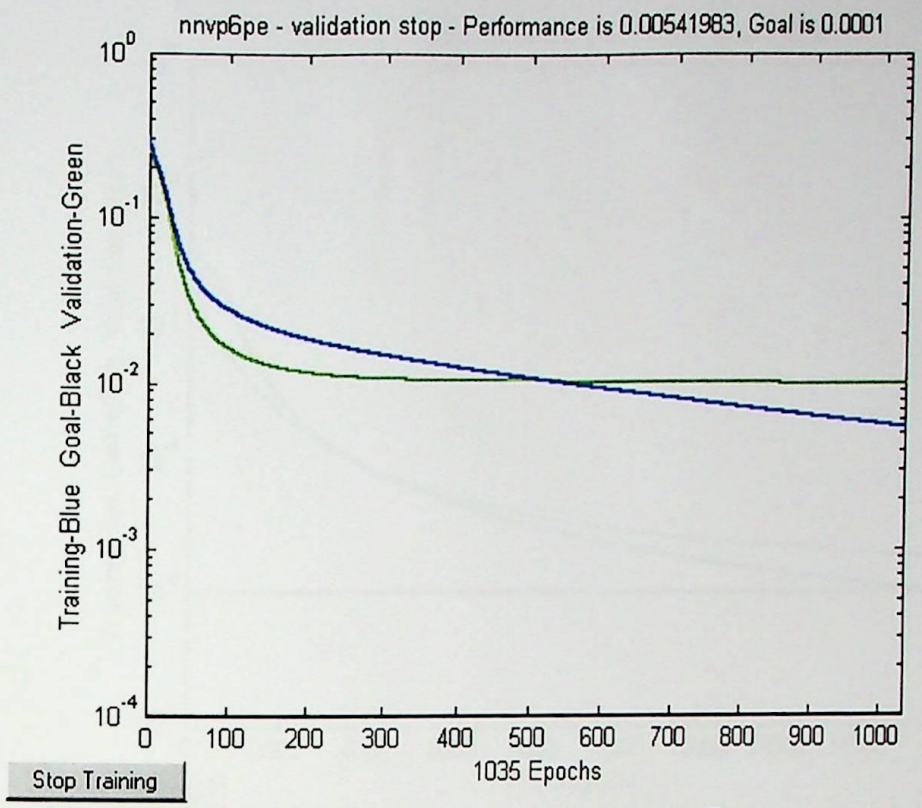


Figura 7.79 - SSE Treinamento e Validação Processamento 4.3.1 NN-PE-32x8x2

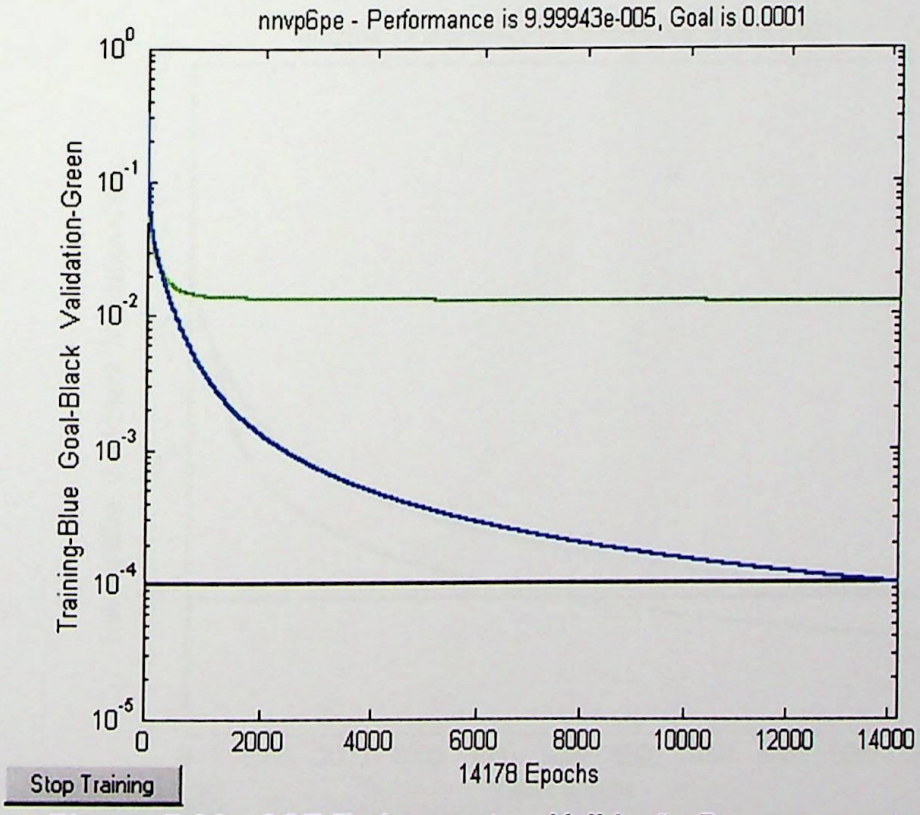


Figura 7.80 - SSE Treinamento e Validação Processamento 4.3.1 NN-PE-32x8x4x2

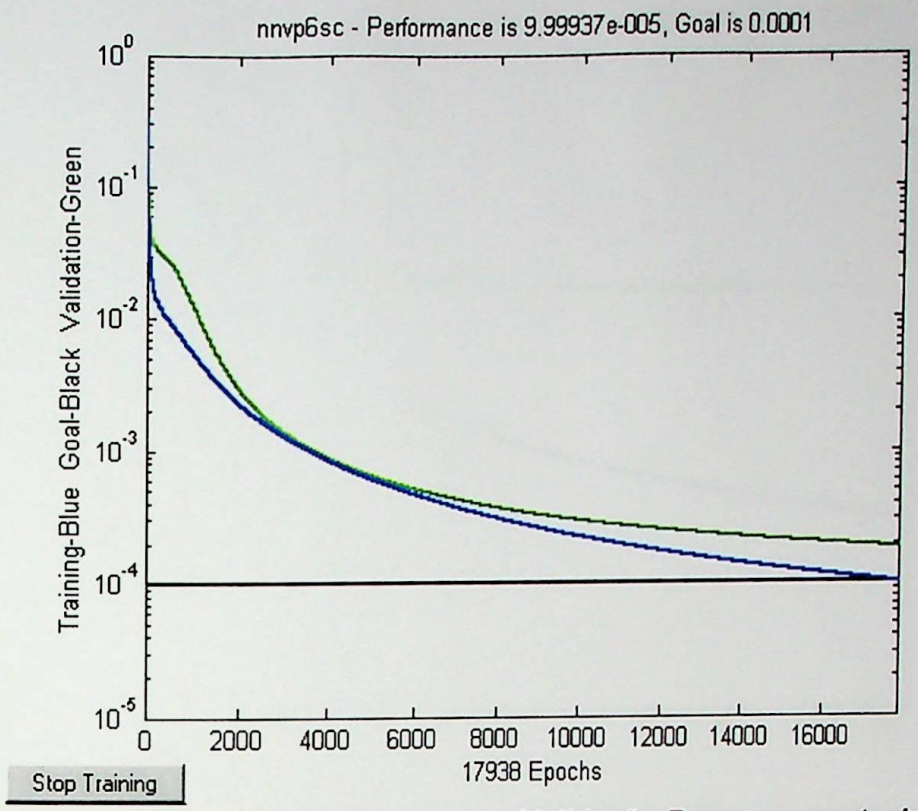


Figura 7.81 - SSE Treinamento e Validação Processamento 4.3.1 NN-SC-32x8x2

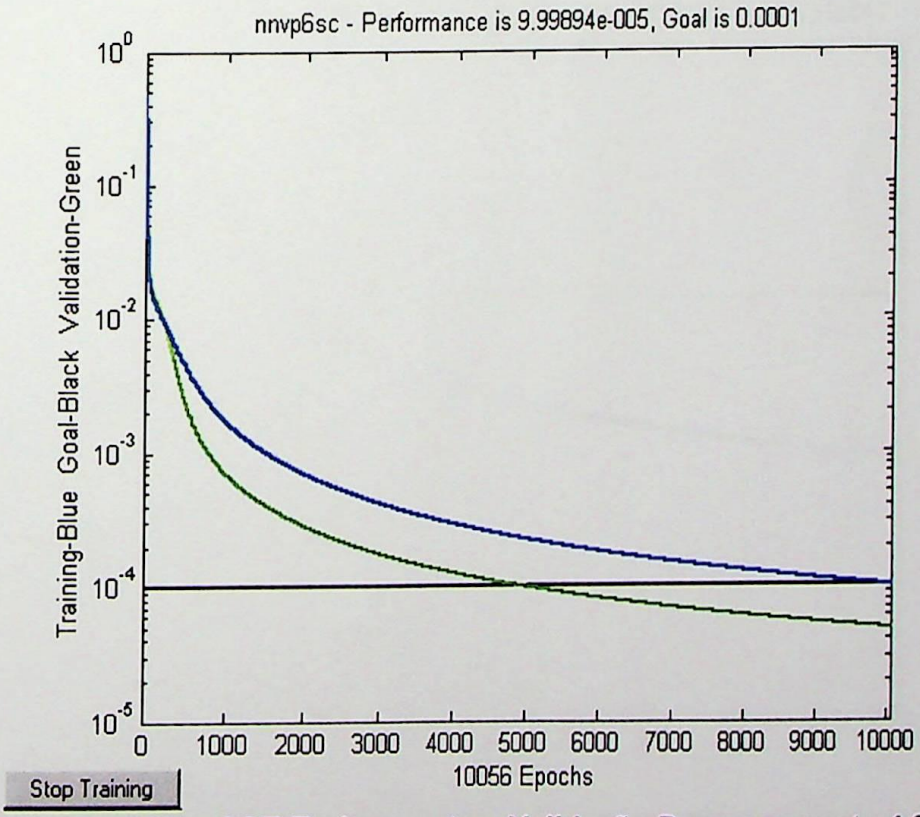


Figura 7.82 - SSE Treinamento e Validação Processamento 4.3.1 NN-SC-32x8x4x2

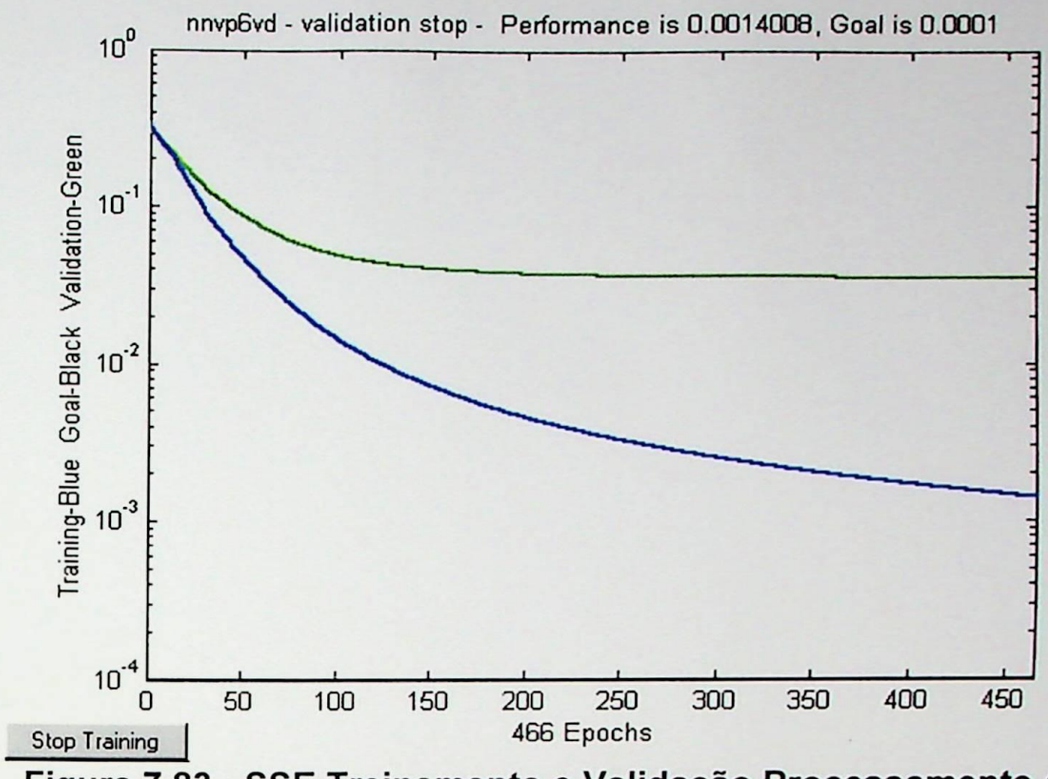


Figura 7.83 - SSE Treinamento e Validação Processamento 4.3.1 NN-VD-32x8x2

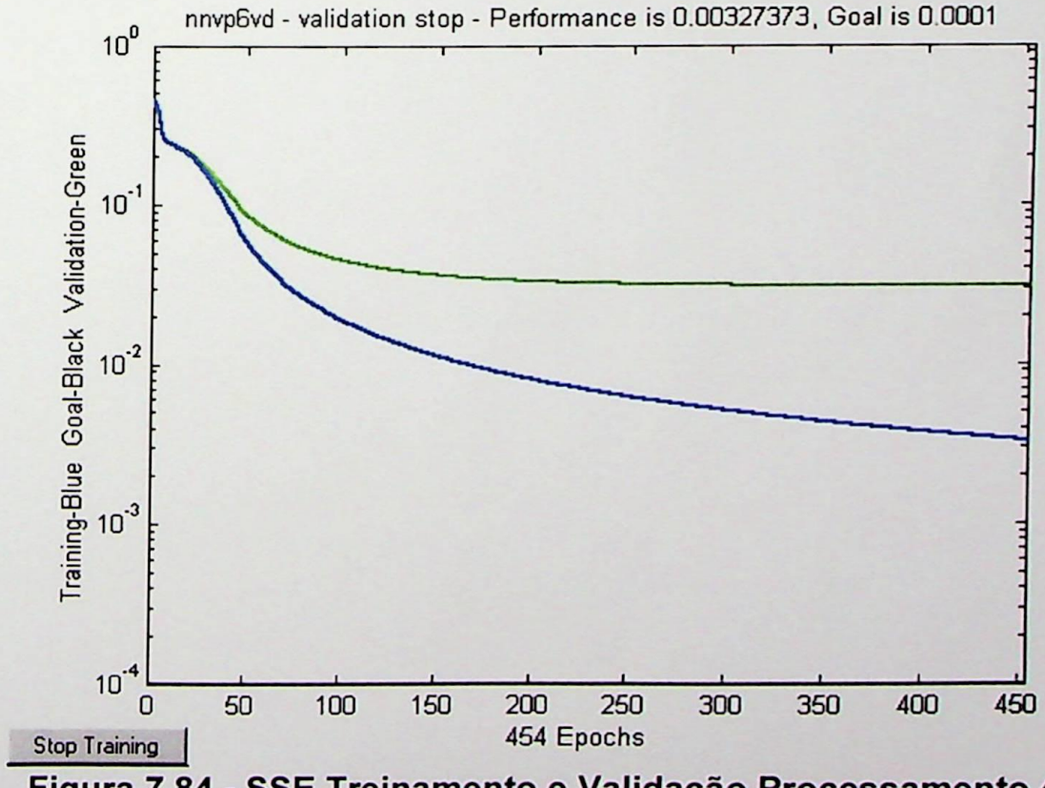


Figura 7.84 - SSE Treinamento e Validação Processamento 4.3.1 NN-VD-32x8x4x2