

Referências bibliográficas

1. HIMMELBLAU, D.M. Use of artificial neural networks in monitor faults and for troubleshooting in the process industries. In: Preprints IFAC Symp. On-line Fault Detection and Supervision in the Chemical Process Industries, **Newark, Delaware, USA**, p. 144-149, 1992.
2. ISERMANN, R. Supervision, fault detection and diagnosis of technical Systems. **Special Section of Control Engineering Practice**, 5, 1997.
3. CHEN, J.; PATTON, R.J. Robust Model-Based Fault Diagnosis for Dynamic Systems. **Kluwer Academic Publishers, Berlin**, 1999.
4. PATTON, R.J.; FRANK, P.M.; CLARK, R. Issues of Fault Diagnosis for Dynamic Systems. Springer-Verlag, Berlin, 2000.
5. KORBICZ, J.; PATAN, K.; KOWAL, M. eds. Fault Diagnosis and Fault Tolerant Control. Challenging Problems of Science - Theory and Applications: **Automatic Control and Robotics**, Academic Publishing House EXIT, Warsaw, 2007.
6. WITCZAK, M. Modelling and Estimation Strategies for Fault Diagnosis of Non- Linear Systems. From Analytical to Soft Computing Approaches. **Lecture Notes in Control and Information Sciences**, Springer-Verlag, Berlin, 2007.
7. ISERMANN, R. Fault diagnosis of machines via parameter estimation and knowledge processing – A tutorial paper. **Automatica**, 29, 1994.
8. PATTON, R.J.; FRANK, P.M.; CLARK, R.N. Issues of Fault Diagnosis for Dynamic Systems. Springer-Verlag, Berlin, 2000.
9. RUTKOWSKI, L. New Soft Computing Techniques for System Modelling, Pattern Classification and Image Processing. Springer-Verlag, Berlin, 2004.
10. NELLES, O. Nonlinear System Identification. From Classical Approaches to Neural Networks and Fuzzy Models. Springer-Verlag, Berlin, 2001.

11. NORGARD, M.; RAVN, O.; POULSEN, N.; HANSEN, L. Networks for Modelling and Control of Dynamic Systems. Springer-Verlag, London, 2000.
12. NARENDRA, K.S.; PARTHASARATHY, K. Identification and control of dynamical systems using neural networks. **IEEE Transactions on Neural Networks**, 1, 1990.
13. HUNT, K.J.; SBARBARO, D.; ZBIKOWSKI, R.; GATHROP, P.J. Neural networks for control systems. A survey. **Automatica**, 28: 1083-1112, 1992.
14. MILLER, W.T.; SUTTON, R.S.; WERBOS, P.J. Neural Networks for Control. **MIT Press**, Cambridge, MA, 1990.
15. HAYKIN, S. Neural Networks. A Comprehensive Foundation, 2nd Edition. Prentice-Hall, New Jersey (1999)
16. ZHANG, J.; MAN, K.F. Time series prediction using RNN in multi-dimension embedding phase space. In: Proc. IEEE Int. Conf. Systems, Man and Cybernetics, San Diego, USA, 11-14 October. Published on CD-ROM, p. 1868-1873, 1998.
17. JANCZAK, A. Identification of Nonlinear Systems Using Neural Networks and Polynomial Models. A Block-oriented Approach. **Lecture Notes in Control and Information Sciences**, Springer-Verlag, Berlin, 2005.
18. PATAN, K.; PARISINI, T. Identification of neural dynamic models for fault detection and isolation: The case of a real sugar evaporation process. **Journal of Process Control**, 15: 67-79, 2005.
19. GUGLIELMI, G.; PARISINI, T.; ROSSI, G. Fault diagnosis and neural networks: A power plant application (keynote paper). **Control Engineering Practice**, 3, 1995.
20. CALADO, J.; KORBICZ, J.; PATAN, K.; PATTON, R.; SA DA COSTA, J. Soft computing approaches to fault diagnosis for dynamic systems. **European Journal of Control**, 7: 248-286, 2001.
21. GLASSER, G.J. Planned Replacement: Some Theory and its Application. **Journal of Quality Technology**, 1: 2, 1969.

22. WEIBULL, W. A Statistical Distribution Function of Wide Applicability. **Journal of Applied Mechanics**, 18: 293-297, 1951.
23. NELSON, W. Applied Life Data Analysis. Wiley & Sons, 1982.
24. CAMPBELL, J.D. and JARDINE, A.K.S. Maintenance Excellence: Optimizing Equipment Life-Cycle Decisions. New York: Marcel Dekker, ch. 12, 2001.
25. SCARF, P.A. On the application of mathematical models in maintenance.
26. BARLOW, R. and HUNTER, L. Optimum preventive maintenance policies, *Oper. Res.*, vol. 8, no. 1, pp. 90–100, Jan./Feb. 1960.
27. SCHWEITZER, P.J. Optimal replacement policies for hyperexponentially and uniformly distributed lifetimes. **Oper. Res.**, vol. 15, no. 2, pp. 360-362, Mar./Apr. 1967.
28. SHEIKH, A.K.; AHMED, M. and BADAR, M.A. Fatigue life prediction of assemblies of rotating parts, *Int. J. Fatigue*, vol. 17, no. 1, pp. 35–41, Jan. 1995. **Eur. J. Oper. Res.**, vol. 99, no. 3, pp. 493–506, Jun. 1997.
29. LIU, H.; MAKIS, V. and JARDINE, A.K.S. Scheduling of the optimal replacement times in a flexible manufacturing system. **Trans. IIE**, vol. 33, n^o. 6, pp. 487–495, Jun. 2001.
30. JARDINE, A.K.S.; BANJEVIC, D. and MAKIS, V. Optimal replacement policy and the structure of software for condition-based maintenance. **J. Qual. Maint. Eng.**, vol. 3, no. 2, pp. 109–119, Jun. 1997. P. J. Vlok, J. L. Coetzee, D. Banjevic, A. K. S. Jardine, and V. Makis,
31. Optimal component replacement decisions using vibration monitoring and the proportional-hazards model. **J. Oper. Res. Soc.**, vol. 53, n^o. 2, pp. 193–202, Feb. 2002.
32. BUNEA, C. and BEDFORD, T. The effect of model uncertainty on maintenance optimization. **IEEE Trans. Rel.**, vol. 51, n^o. 4, pp. 486–493, Dec. 2002.

33. COLEN, F.P.A. and DEKKER, R. Analysis of a 2-phase model for optimization of condition monitoring intervals. **IEEE Trans. Rel.**, vol. 44, n^o. 3, pp. 505–511, Sep. 1995.
34. MAILLART, L.M. and POLLOCK, S.M. Cost-optimal condition monitoring for predictive maintenance of 2-phase system. **IEEE Trans. Rel.**, vol. 51, n^o. 3, pp. 322–330, Sep. 2002.
35. WANG, W. A model to determine the optimal critical level and the monitoring intervals in condition-based maintenance. **Int. J. Prod. Res.**, vol. 38, n^o. 6, pp. 1425–1436, Apr. 2000.
36. LU, C. and MEEKER, W. Using degradation measures to estimate atime-to-failure distribution. **Technometrics**, vol. 35, n^o. 2, pp. 161–174, May 1993.
37. SAGLAM, H. and UNUVAR, A. T01 condition monitoring in milling based on cutting forces by a neural network. **Int. J. Prod. Res.**, vol. 41, n^o. 7, pp. 1519–1532, May 2003.
38. VEMURI, A.T.; POLYCARPOU, M.M. and DIAKOURTIS, S.A. Neural network based fault detection in robotic manipulators. **IEEE Trans. Robot. Autom.**, vol. 14, n^o. 2, pp. 342–347, Apr. 1998.
39. ALGUINDIGUE, I.E.; LOSKIEWICZ-BUCZAK, A. and UHRIG, R.E. Monitoring and diagnosis of rolling element bearings using artificial neural networks. **IEEE Trans. Ind. Electron.**, vol. 40, n^o. 2, pp. 209–217, Apr. 1993.
40. SHAO, Y. and NEZU, K. Prognosis of remaining bearing life using neural networks. **Proc. Inst. Mech. Eng.**, Part I, J. Syst. Control Eng., vol. 214, n^o. 3, pp. 217–230, Jun. 2000.
41. GEBRAEEL, N.Z.; LAWLEY, M.A. and LIU, R. Vibration-based condition monitoring of thrust bearings for maintenance management. In: Proc. ANNIE Smart Eng. Syst. Des.: Neural Netw., Fuzzy Logic, Evolutionary Program., Artif. Life and Data Mining, St. Louis, MO, 2002, pp. 543–551.
42. GEBRAEEL, N.Z.; M. A. LAWLEY, M.A.; LIU, R. and PARMESHWARAN, V. Residual life predictions from vibration-based

degradation signals: A neural network approach. **IEEE Trans. Ind. Electron**, vol. 51, n^o. 3, pp. 694–700, Jun. 2004.

43. BERG, M. The marginal cost analysis and its application to repair and replacement policies. **European Journal of Operational Research**, 82: 214-224, 1995.

44. BERG, M. and EPSTEIN, A. A modified block replacement policy, **Naval Research Logistics Quarterly**, 23: 15-24, 1976.

45. SCARF, P.A.; DWIGHT, R. and AL-MUSRATI, A. On reliability criteria and the implied cost of failure for a maintained component. **Reliability Engineering and System Safety**, 89: 199-207, 2005.

46. MAKIS, V. & JARDINE, A.K.S. Optimal Replacement in the Proportional Hazards Model. **INFOR**, 30(2), 172, 1992.

47. PARK, K.S. Optimal wear-limit replacement with wear-dependent failure. **IEEE Transactions on Reliability**, 37: 293-294, 1988.

48. WANG, W. A model to predict the residual life of rolling element bearings given monitoring condition information to date. I.M.A. **Journal of Management Mathematics**, 13: 3-16, 2002.

49. CHRISTER, A.H. and WANG, W. A model of condition monitoring of production plant. **Intl. Journal of Production Research**, 30: 2199-2211, 1992.

50. COLEN, F.P.A. and DEKKER, R. Analysis of a 2-phase model for optimization of condition monitoring intervals. **IEEE Transactions on Reliability**, 55: 505-511, 1995.

51. CHRISTER, A.H. Developments in delay time analysis for modelling plant maintenance. **Journal of the Operational Research Society**, 50: 1120-1137, 1999.

52. BAKER, R.D. and WANG, W. Developing and testing the delay time model. **Journal of the Operational Research Society**, 44: 361-374, 1992.

53. WU, SZE-JUNG. A.; GEBRAEEL, N. and LAWLEY, M.A. Neural Network Integrated Decision Support System for Condition-Based Optimal Predictive

Maintenance Policy. **IEEE Transactions on Systems, Man, and Cybernetics** – part a: systems and humans, vol. 37, n^o. 2, march 2007.

54. DIETZ, W.E. Pattern-based fault diagnosis using neural networks, 1988.
55. ZHANG, J. On-line process fault diagnosis using neural network techniques, 1992.
56. SIMANI, S. and FANTUZZI, C. Fault diagnosis in power plant using neural networks, 2000.
57. LU, J. An Evaluation of Engine Faults Diagnostics Using Artificial Neural Networks, 2001.
58. KIMMICH, F.; SCHWARTE, A. and ISERMANN, R. Fault detection for modern Diesel engines using signal- and process model-based methods, 2004.
59. PAULRAJ, M.P.; SAZALI, Y.N.; SHAIFUDIN, A.B.D. and HAMID HEMA, C. R. Intelligent vehicle fault diagnosis system using Neural Networks, 2007.
60. ZHENG, Z.; XINYU, S. and DAOYUAN, Y.U. Fault Diagnosis of a wheel Loader by Artificial Neural Networks and Fuzzy Logic, 2006.
61. HUIQING, L.; JINYAN, L. A Comparative Study on Feature Selection and Classification Methods Using Gene Expression Proles and Proteomic Patterns, 2002.
62. SAWILOWSKY, S.S. Fermat, Schubert, Einstein, and Behrens–Fisher: The Probable Difference Between Two Means When $\sigma_1 \neq \sigma_2$, 2002.
63. KARPENKO and SEPEHRI. Neural network classifiers applied to condition monitoring of a pneumatic process valve actuator. **Engineering Applications of Artificial Intelligence**, v. 15, i3-4, p. 273-283, 2002.
64. DIETZ, W.E. Pattern-based fault diagnosis using neural networks, International conference on Industrial and engineering applications of artificial intelligence and expert systems, 1988.
65. MOUBRAY, J. Reliability-centred maintenance, 1997.

Apêndice

A1

Falta de Óleo no Motor

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada pela falta de óleo no motor do equipamento. Essa falha é considerada crítica, pois a falta de lubrificação no motor acelera o desgaste dos componentes do motor, reduzindo sua vida útil.

A1.1

Topologia da Rede

Sendo o número de amostras dentro da classe 636, foram selecionadas aleatoriamente mais 636 amostras fora da classe. Retirando 10% do conjunto de dados para a fase de teste, tem-se 1144 amostras para a fase de treinamento. Com isso, o número aproximado de entradas, seguindo a mesma metodologia adotada para manter o número de neurônios na camada oculta entre 2 e 4, é exibido na tabela 4.7.

Tabela 4.7 – Número aproximado de variáveis de entrada

Número de neurônios na camada escondida	2	3	4
Número de entradas permitidas para a rede	$n_e \approx 35$	$n_e \approx 21$	$n_e \approx 15$

A1.2

Rede com o Melhor Desempenho

Foram selecionadas as 20 variáveis mais relevantes para a classificação dessa falha para a fase de treinamento da rede.

Tabela 4.8 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	14; 23; 16; 21; 22; 20; 27; 36; 4; 8; 11; 6; 25; 15; 123; 13;7;10;37;116;40
------------------------------------------------------	-----------------------------------------------------------------------------

* a tabela de decodificação dos indicadores segue no apêndice

Das variáveis selecionadas, vale ressaltar as que estão ligadas à temperatura do freio 21, 22 e 23, pois o compartimento de óleo é compartilhado com a lubrificação do motor, além de indicadores que indicam sobrecarga no equipamento, como a diferença nos cilindros de suspensão, 14 e 27, além do indicador da pressão do óleo 6.

A rede neural com 3 neurônios na camada oculta atingiu o melhor resultado, com os parâmetros de agregação dos dados $\Delta = 4$ dias e uma janela $Jt = 4$ dias.

Tabela 4.9 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
2%	5%	8%

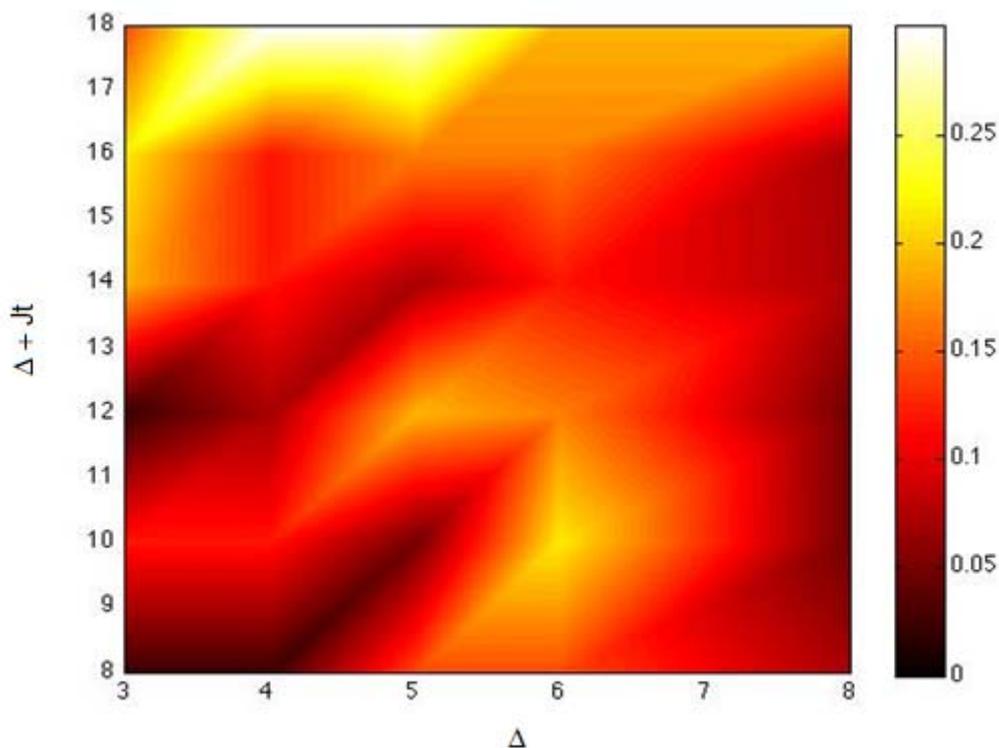


Figura 4.2 – Mapa de desempenho da classificação da Falta de óleo no motor

O índice de acerto da rede ficou em média em 92%, com uma antecedência de 4 dias à falha, que pode evitar não somente a falha mas danos consequentes das falhas.

A1.3

Baixo Rendimento do Motor

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada pelo baixo rendimento do equipamento, pois isto impacta diretamente na produção da máquina, e é caracterizada por perda de potência no motor, o que impacta diretamente na velocidade do equipamento, ou até sua parada por completo.

A1.3.1

Topologia da Rede

Sendo o número de amostras dentro do padrão 528, tem-se 1056 amostras para o treinamento. Separando-se 10% para a fase de testes, restam 950 amostras para a fase de treinamento. Para manter a camada escondida com 2 a 4 neurônios a tabela 4.10 exibe o número aproximado de variáveis de entradas a serem utilizadas.

Tabela 4.10 – Número aproximado de variáveis de entrada

Número de neurônios na camada escondida	2	3	4
Número de entradas permitidas para a rede	$n_e \approx 30$	$n_e \approx 18$	$n_e \approx 13$

A1.3.2

Rede com o Melhor Desempenho

Para a rede que teve a melhor classificação da classe de baixo rendimento, foram selecionadas 14 variáveis com maior influência na saída que estão listadas na tabela 4.11 por ordem de importância.

Tabela 4.11 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	33; 34; 90;123; 130; 63; 116; 129; 91; 83;58;31;125;117
------------------------------------------------------	---------------------------------------------------------

* a tabela de decodificação dos indicadores segue no apêndice

A pressão do óleo no motor dos indicadores 33 e 34, além de problemas em ligar o equipamento (indicados pela variável 90) tiveram bastante influência na separação dessa falha.

Conforme é possível verificar no gráfico 4.3, o melhor desempenho da rede foi atingido com uma camada escondida de 4 neurônios. Conforme foi discutido na metodologia, a rede com o maior parâmetro de atraso é considerada

melhor. Nesse caso o $\Delta = 8$ dias teve o melhor desempenho com $Jt = 10$ dias. A tabela 4.12 exibe o desempenho da rede nas fases de treinamento, validação e teste.

Tabela 4.12 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
4%	5%	8%

* a tabela de decodificação dos indicadores segue no apêndice

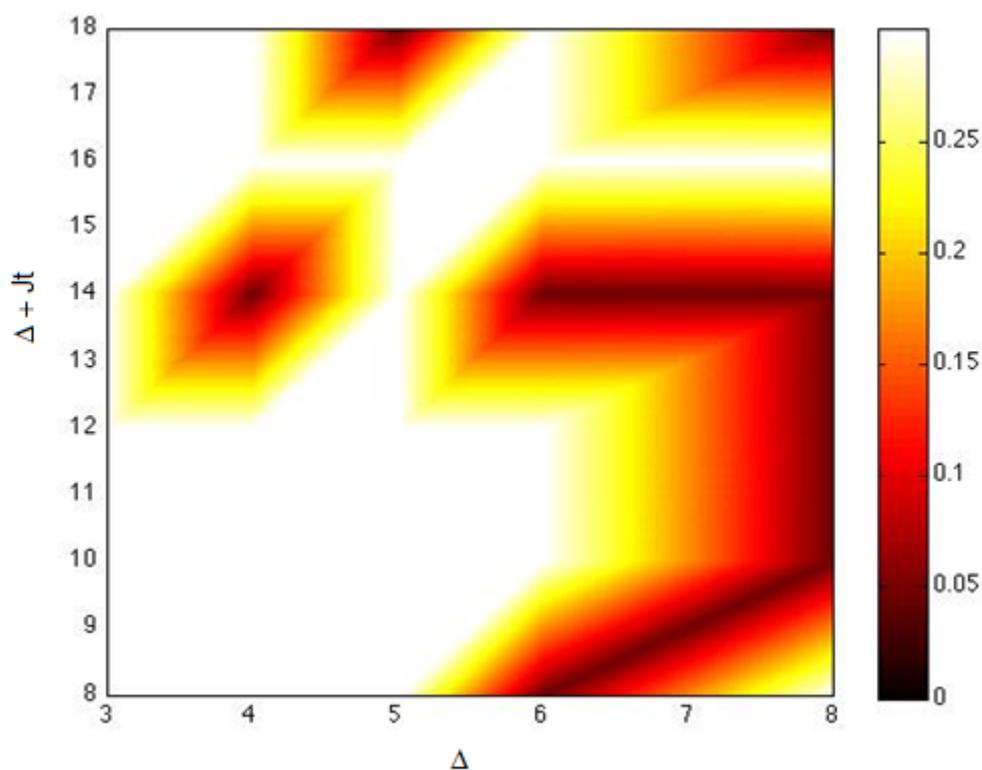


Figura 4.3 – Mapa de desempenho da classificação do baixo rendimento do motor

O erro médio de classificação dessa rede foi de 8% com 8 dias de antecedência, o que é bastante satisfatório para classificação de falhas.

A1.4

Filtros de Combustível Obstruídos

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada pela obstrução dos filtros do combustível do equipamento. A máquina possui um sistema de *bypass* do filtro, o que permite a contaminação do sistema de queima de combustível, que pode levar a problemas mais graves no equipamento.

A1.4.1

Topologia da Rede

Sendo o número de amostras dentro do padrão 282, o grupo de treinamento tem 564 amostras, das quais 10% foi separado para a fase de teste. Logo, tem-se 507 amostras para a fase de treinamento. Com isso, o número de entradas para manter de 2 a 4 neurônios na camada escondida está descrito na tabela 4.13.

Tabela 4.13 – Número aproximado de variáveis de entrada

Nº neurônios na camada escondida	2	3	4
Nº de entradas permitidas para a rede	$n_e \approx 15$	$n_e \approx 9$	$n_e \approx 6$

* a tabela de decodificação dos indicadores segue no apêndice

A1.4.2

Rede com o Melhor Desempenho

Foram utilizadas 9 variáveis pela rede de melhor desempenho que estão ordenadas por relevância na identificação da falha de filtro obstruído.

Tabela 4.14 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	32;17;80;128;71;111;73;123;130
------------------------------------------------------	--------------------------------

* a tabela de decodificação dos indicadores segue no apêndice

O melhor desempenho da rede foi atingido com uma rede de 2 neurônios na camada escondida. Fica claro no gráfico que, para 3 combinações dos parâmetros Δ e Jt , o desempenho da rede foi melhor porém, pela importância da antecedência da classificação, a rede com maior Δ foi selecionada. A rede com o parâmetro $\Delta = 5$ dias e $Jt = 11$ dias foi selecionada e seus resultados apresentados na tabela 4.15.

Tabela 4.15 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
3%	4%	6%

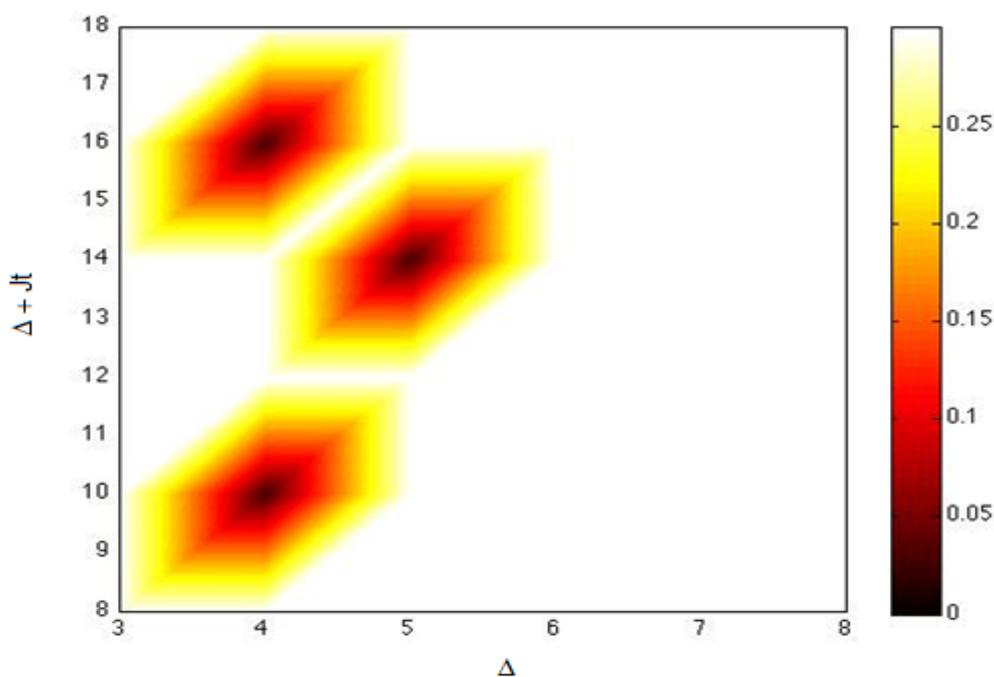


Figura 4.4 – Mapa de desempenho da classificação do filtro de combustível obstruído

O resultado para a classificação dessa falha foi bastante satisfatório, tendo em vista o alto índice de acerto e a antecedência de 5 dias à falha.

A1.5

Bateria Danificada

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada por falta de energia elétrica no equipamento por problemas na bateria. Para o downtime foi contabilizado o tempo desde a parada do equipamento até a liberação da máquina. Problemas com bateria podem levar à queima errada de combustível, aumento no consumo do mesmo, assim como falhas no acionamento de implementos do equipamento.

A1.5.1

Topologia da Rede

Sendo o número de amostras dentro do padrão 201, para balancear a base de treinamento foi utilizado o mesmo número de amostras fora da classe. 10% do total foi separado para a fase de teste e com isso tem-se 361 amostras para a fase de treinamento. Para manter o número de neurônios na camada oculta entre 2 e 4, o número de entradas aproximado fica explicitada na tabela abaixo.

Tabela 4.16 – Número aproximado de variáveis de entrada

Nº de neurônios na camada escondida	2	3	4
Nº de entradas permitidas para a rede	$n_e \approx 10$	$n_e \approx 6$	$n_e \approx 3$

A1.5.2

Rede com o Melhor Desempenho

A rede com o melhor desempenho médio utilizou 7 variáveis de entrada que estão listadas em ordem de importância na tabela a seguir.

Tabela 4.17 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	33;14;23;16;21;22;108
------------------------------------------------------	-----------------------

* a tabela de decodificação dos indicadores segue no apêndice

Os erros de treinamento validação e teste são exibidos na tabela 4.18.

Tabela 4.18 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
8%	9%	10%

Conforme é possível verificar no gráfico 4.6, o melhor desempenho da rede foi alcançado com o parâmetro $\Delta = 3$ dias e uma janela $Jt = 13$ dias.

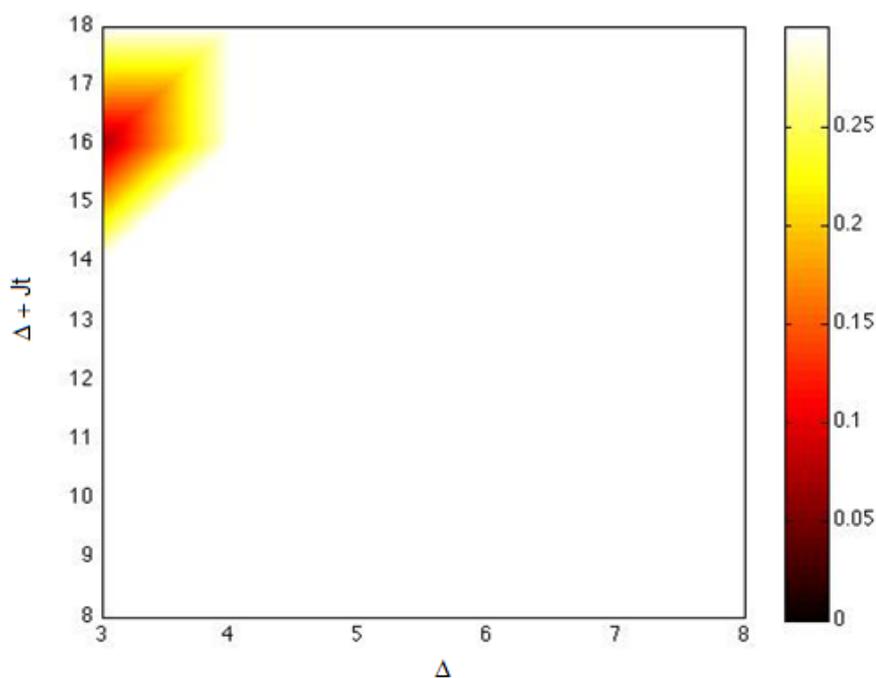


Figura 4.6 – Mapa de desempenho da classificação de bateria danificada

O índice de acerto para essa falha foi em média 90%, o que pode ser considerado bastante satisfatório para classificação de padrão de falhas.

A1.6

Sem Partida

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada por equipamentos que não conseguiam ser religados.

A1.6.1

Topologia da Rede

Sendo o número de amostras dentro do padrão 951, unidas a 951 amostras e separando-se 10% para treinamento, tem-se 1710 amostras para a fase de treinamento. Como o número de amostras é muito alto, será possível utilizar todas as variáveis selecionadas pelo teste-t.

A1.6.2

Rede com o Melhor Desempenho

Para a rede com o melhor desempenho para classificação da falha *Sem Partida* foram selecionadas 14 variáveis que estão ordenadas por ordem de importância na tabela 4.19.

Tabela 4.19 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	14;16;27;8;11;15;2;13;10;26;3;24;38;41
------------------------------------------------------	----------------------------------------

* a tabela de decodificação dos indicadores segue no apêndice

O melhor desempenho da rede foi atingido com 4 neurônios na camada escondida e, conforme é possível verificar no gráfico 4.7, tal desempenho foi atingido com o parâmetro $\Delta = 4$ dias e uma janela $Jt = 8$ dias, conforme indicado

na tabela 4.20.

Tabela 4.20 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
3%	4%	5%

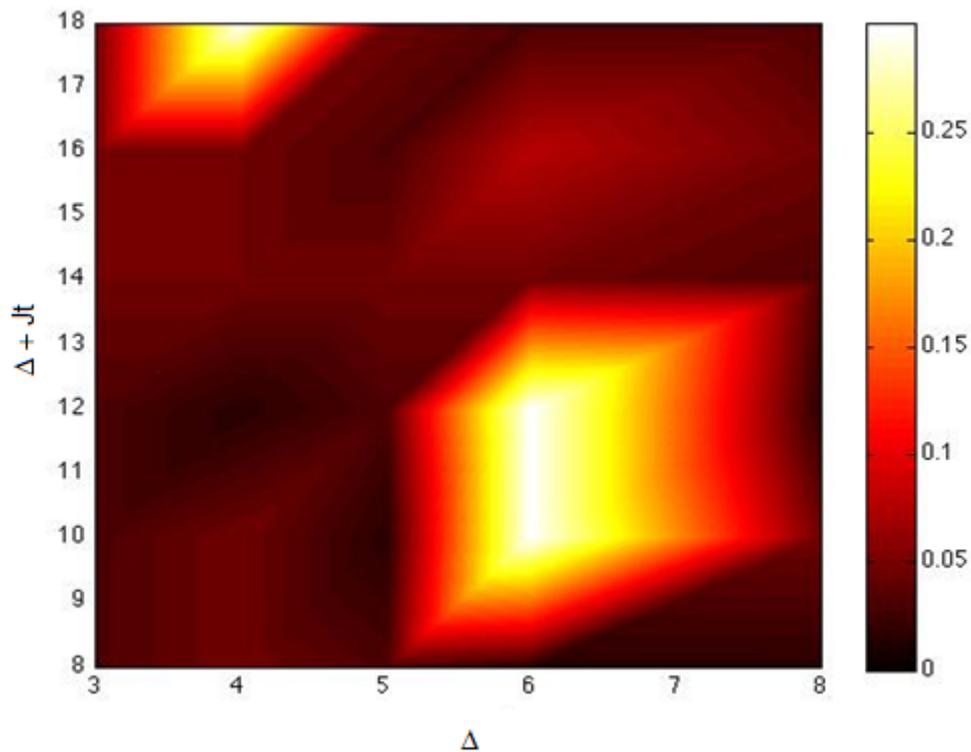


Figura 4.7 – Mapa de desempenho da classificação de equipamento Sem Partida

O desempenho da rede na classificação de da falha *Sem Partida* foi de 95%, o que é bastante satisfatório com uma antecedência de 4 dias, o que na prática permite a parada da máquina para a correção do problema.

A1.7

Filtro de Óleo Obstruído

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada por equipamentos que possuíam obstrução do filtro de óleo. Esse problema é crítico pois, com a passagem de

partículas para as partes internas do motor, inicia-se um aumento do desgaste interno e aumento de temperatura devido ao atrito das partículas. Para o downtime foi contabilizado o tempo desde a parada do equipamento até a liberação da máquina.

A1.7.1

Topologia da Rede

Sendo o número de amostras dentro da classe 58, foi utilizada a mesma quantidade de amostras fora da classe. Como em todas as classificações, foi separado 10% da total para o grupo de teste, e com isso 104 amostras foram utilizadas para a fase de treinamento. Pelo baixo número de amostras, foram utilizados apenas 2 neurônios na camada escondida.

A1.7.2

Rede com o Melhor Desempenho

Para essa classe foram selecionadas 5 variáveis de entrada, que são apresentadas na tabela 4.21 em ordem de relevância.

Tabela 4.21 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	33;23;16;11;118
------------------------------------------------------	-----------------

* a tabela de decodificação dos indicadores segue no apêndice

O melhor desempenho da rede foi atingido com o parâmetro $\Delta = 5$ dias e uma janela $J_t = 11$ dias. A tabela 4.22 exhibe o desempenho da rede na fase de treinamento e validação, assim como o erro de teste.

Tabela 4.22 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
35%	37%	40%

O desempenho dessa rede não foi satisfatório, uma vez que possivelmente essa falha não é observável pelos indicadores que são monitorados. Essa rede não será utilizada na próxima seção, pois o índice de acerto é muito baixo.

A1.8

Obstrução do Filtro de Ar

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada por obstrução no filtro de ar do motor, o que possibilita a entrada de detritos no motor e reduz a quantidade e qualidade do ar injetado para a combustão.

A1.8.1

Tratamento da Base de Dados

Sendo o número de amostras dentro do padrão 100, tem-se 180 amostras para a fase de treinamento e, pelo baixo número de amostras será utilizado apenas 2 neurônios na camada escondida.

A1.8.2

Rede com o Melhor Desempenho

Foram selecionadas 6 variáveis pelo teste-t que estão ordenadas por relevância na tabela 4.23.

Tabela 4.23 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	33;23;16;21;1;18
------------------------------------------------------	------------------

- a tabela de decodificação dos indicadores segue no apêndice

A variável 1 indica alteração da pressão da turbina, que está diretamente ligado ao sistema de admissão de ar do motor, onde os filtros em questão estão posicionados.

Conforme é possível verificar no gráfico 4.8, o melhor desempenho da rede foi atingido com o parâmetro $\Delta = 5$ dias e uma janela $Jt = 6$ dias e 2 neurônios na camada escondida. A tabela 4.24 exibe o desempenho da rede na fase de treinamento e validação, assim como o erro de teste.

Tabela 4.24 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
11%	13%	15%

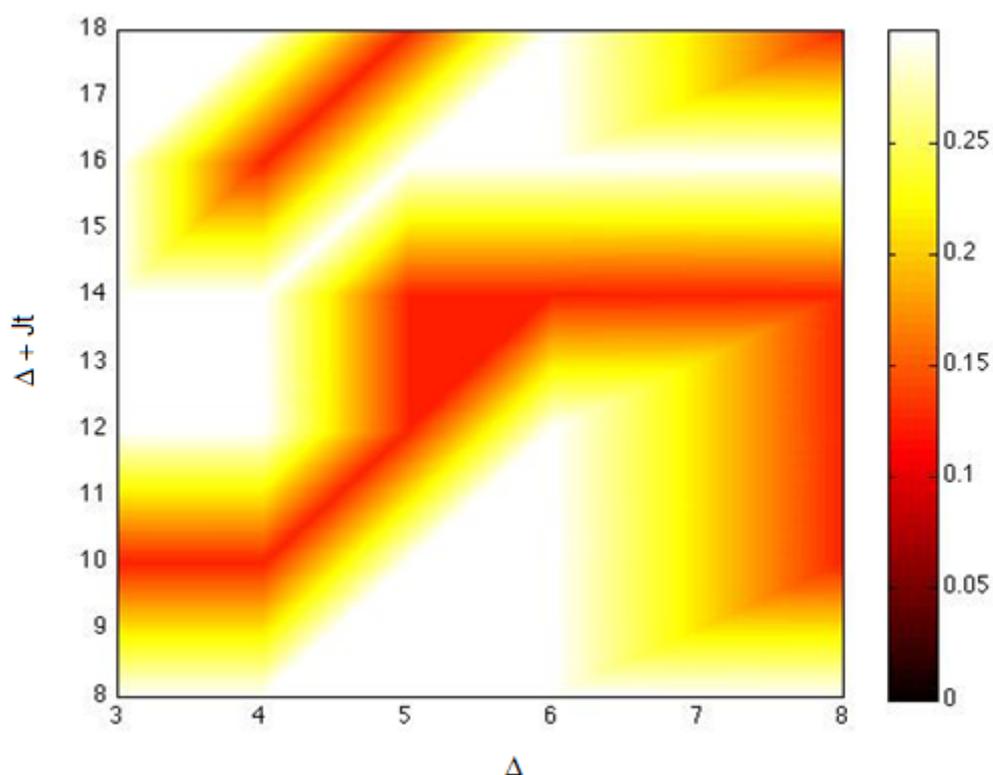


Figura 4.8 – Mapa de desempenho da classificação de obstrução do filtro de ar

Essa rede apresentou um desempenho mediano, com erro médio de 15%, porém, pelo baixo número de amostras o resultado é considerado satisfatório e pode ser melhorado conforme mais padrões forem acrescentados para o seu treinamento.

A1.9

Nível de Óleo no Conversor de Torque Fora do Normal

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada por equipamentos que possuíam o nível acima ou abaixo do normal, o que indica a passagem de fluido entre os compartimentos.

A1.9.1

Topologia da Rede

Sendo o número de amostras dentro do padrão 470 pelo mesmo raciocínio adotado anteriormente tem-se 846 amostras para a fase de treinamento e, com isso, o número de entradas fica restrito. Dependendo do número de neurônios na camada escondida que se deseja utilizar, o número aproximado de neurônios na camada está descrito na tabela 4.25.

Tabela 4.25 – Número aproximado de variáveis de entrada

Nº de neurônios na camada escondida	2	3	4
Nº de entradas permitidas para a rede	$n_e \approx 26$	$n_e \approx 17$	$n_e \approx 12$

A1.9.2

Rede com o Melhor Desempenho

A rede com o melhor desempenho utilizou 17 variáveis de entrada, dentre as quais estão indicadores de temperatura do sistema de lubrificação da transmissão (variável 42) o que é um sintoma claro da deficiência do sistema de lubrificação da transmissão.

Tabela 4.26 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	32;80;42;61;18;52;111;123;130;65;44;101;40;129;91;53;112
------------------------------------------------------	----------------------------------------------------------

* a tabela de decodificação dos indicadores segue no apêndice

A rede com melhor desempenho utilizou 3 neurônios na camada escondida e, conforme fica explícito no gráfico 4.9, o melhor desempenho da rede foi atingido com o parâmetro $\Delta = 5$ dias e uma janela $Jt = 9$ dias. A tabela 4.27 exhibe os erros de classificação médios de cada um dos grupos de dados.

Tabela 4.27 – Desempenho médio da classificação

Erro treinamento	Erro validação	Erro teste
4%	5%	5%

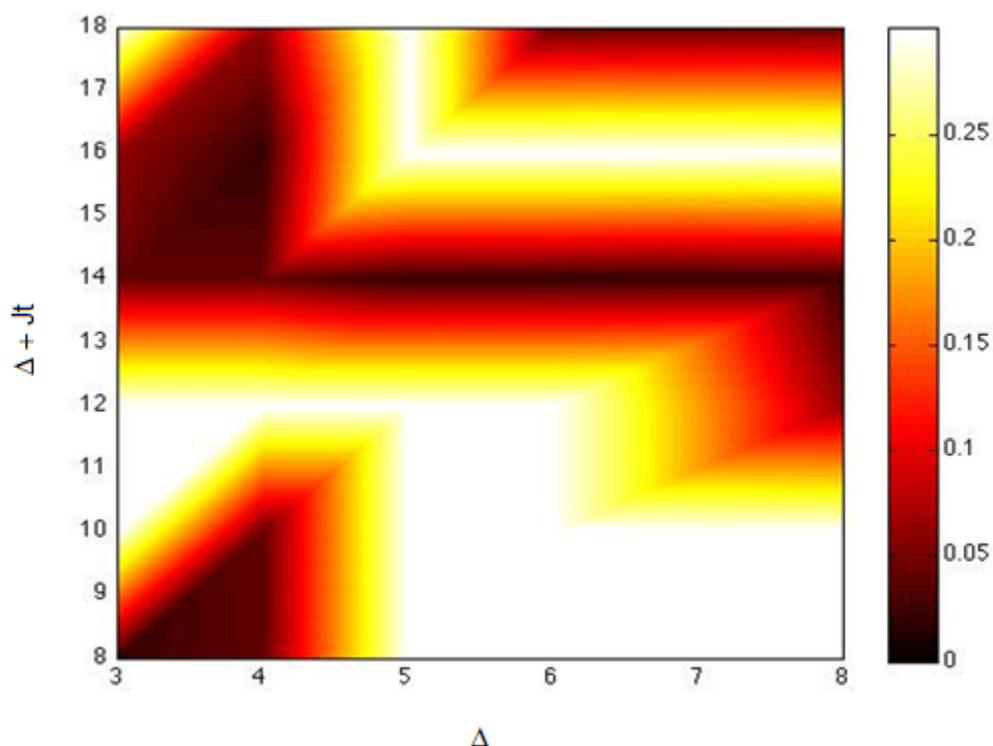


Figura 4.9 – Mapa de desempenho da classificação do nível de óleo no conversor de torque fora do normal

O resultado dessa rede foi bastante satisfatório, dado que seu índice de acerto foi de 95%, com um intervalo entre a detecção do padrão e a ocorrência da falha de 5 dias, o que permite a programação de uma parada para ser realizada a manutenção necessária.

A1.10

Falha no Freio Retardo

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada pela falha no freio retardo, que funciona como um freio motor, o que tem impacto tanto no downtime da máquina quanto na segurança dos operadores.

A1.10.1

Topologia da Rede

Sendo o número de amostras dentro da classe 174, pela mesma lógica utilizada anteriormente tem-se 312 amostras para utilizar na fase de treinamento.

Tabela 4.28 – Número aproximado de variáveis de entrada

Nº de neurônios na camada escondida	2	3	4
Nº de entradas permitidas para a rede	10	6	4

A1.10.2

Rede com o Melhor Desempenho

O melhor desempenho dessa rede utilizou 10 variáveis de entrada e 2 neurônios na camada oculta. As variáveis selecionadas estão listadas na tabela 4.29 e ordenadas por relevância na classificação da falha.

Tabela 4.29 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	14;23;16;21;22;20;27;36;4;8
------------------------------------------------------	-----------------------------

* a tabela de decodificação dos indicadores segue no apêndice

No gráfico 4.10 é possível identificar que o melhor desempenho da rede foi atingido com o parâmetro $\Delta = 8$ dias e uma janela $Jt = 7$ dias. A tabela 4.30 exhibe o desempenho da rede na classificação.

Tabela 4.30 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
12%	13%	15%

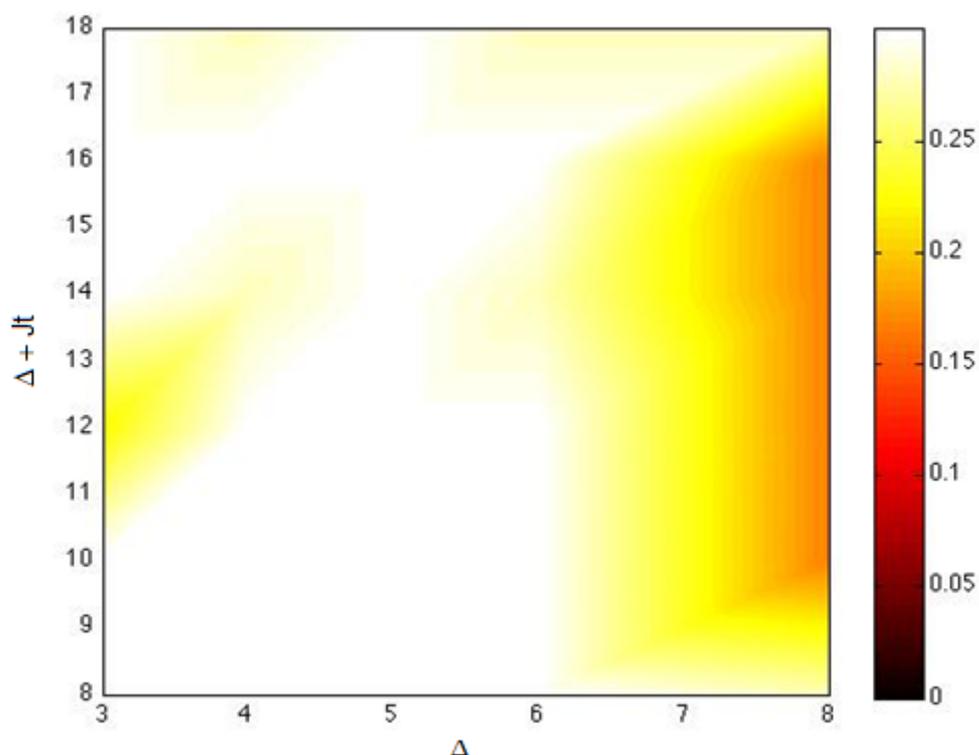


Figura 4.10 – Mapa de desempenho da classificação da falha no freio retardo

O desempenho da rede é considerado satisfatório para a classificação de falhas em equipamentos móveis.

A1.11

Marcha não Engata

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada por equipamento nos quais não se conseguia efetuar mudança de marcha, o que determina a parada imediata do equipamento.

A1.11.1

Topologia da Rede

Sendo o número de amostras dentro do padrão 211, duplicando o número de amostras para se obter um grupo de treinamento balanceado e separando 10% das amostras para o grupo de teste tem-se 380 amostras para a fase de treinamento. Com isso, o número de aproximado de variáveis de entrada para se manter a camada oculta com 2 a 4 neurônios é explicitado na tabela 4.31.

Tabela 4.31 – Número aproximado de variáveis de entrada

Nº de neurônios na camada escondida	2	3	4
Nº de entradas permitidas para a rede	$n_e \approx 11$	$n_e \approx 6$	$n_e \approx 4$

A1.11.2

Rede com o Melhor Desempenho

Conforme é possível verificar no gráfico 4.11, o melhor desempenho da rede foi alcançado com o parâmetro Δ de 7 dias e uma janela Jt de 11 dias e com 2 neurônios na camada oculta. A tabela 4.32 exhibe o desempenho da rede na fase de treinamento e validação, assim como o erro de teste.

Tabela 4.32 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
2%	3%	5%

Tabela 4.33 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	33;16;28;34;15;123;130;13;82;12;1;129;56;125;124
------------------------------------------------------	--------------------------------------------------

- a tabela de decodificação dos indicadores segue no apêndice

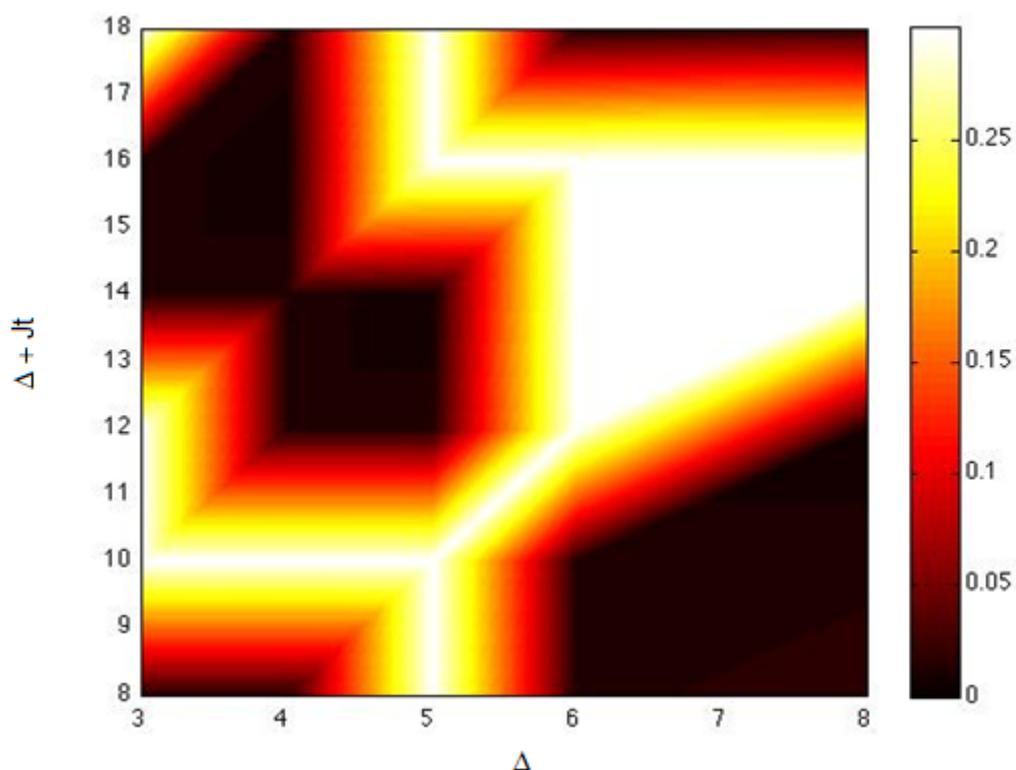


Figura 4.11 – Mapa de desempenho

Para essa rede vários intervalos de tempo tiveram um resultado satisfatório porém, para a programação da manutenção, quanto maior for esse intervalo melhor.

A1.12

Super Aquecimento do Conversor de Torque

Nessa categoria foram utilizados todos os registros de paradas do equipamento para realizar manutenção causada pelo super aquecimento do conversor de torque.

A1.12.1

Topologia da Rede

Sendo o número de amostras dentro da classe 130, e utilizando o mesmo raciocínio já apresentado, tem-se 234 amostras para a fase de treinamento e para se manter de 2 a 4 neurônios na camada oculta o número aproximado de neurônios está descrito na tabela 4.34.

Tabela 4.34 – Número aproximado de variáveis de entrada

Nº de neurônios na camada escondida	2	3	4
Nº de entradas permitidas para a rede	12, 8, 6	12, 8, 3	12, 8, 2

A1.12.2

Rede com o Melhor Desempenho

A rede com o melhor desempenho selecionou 8 variáveis, que estão ordenadas por relevância na tabela 4.35.

Tabela 4.35 – Variáveis utilizadas pela rede de melhor desempenho

Variáveis que foram selecionadas utilizando teste-t*	14;22;20;27;36;4;118;80
------------------------------------------------------	-------------------------

* a tabela de decodificação dos indicadores segue no apêndice

O melhor desempenho foi atingido com o parâmetro $\Delta = 4$ dias e uma janela $J_t = 13$ dias, conforme é possível visualizar na figura 4.12, e 2 neurônios na camada escondida. A tabela 4.36 exibe o desempenho da rede nas etapas do treinamento.

Tabela 4.36 – Erro médio de classificação

Erro treinamento	Erro validação	Erro teste
6%	8%	9%

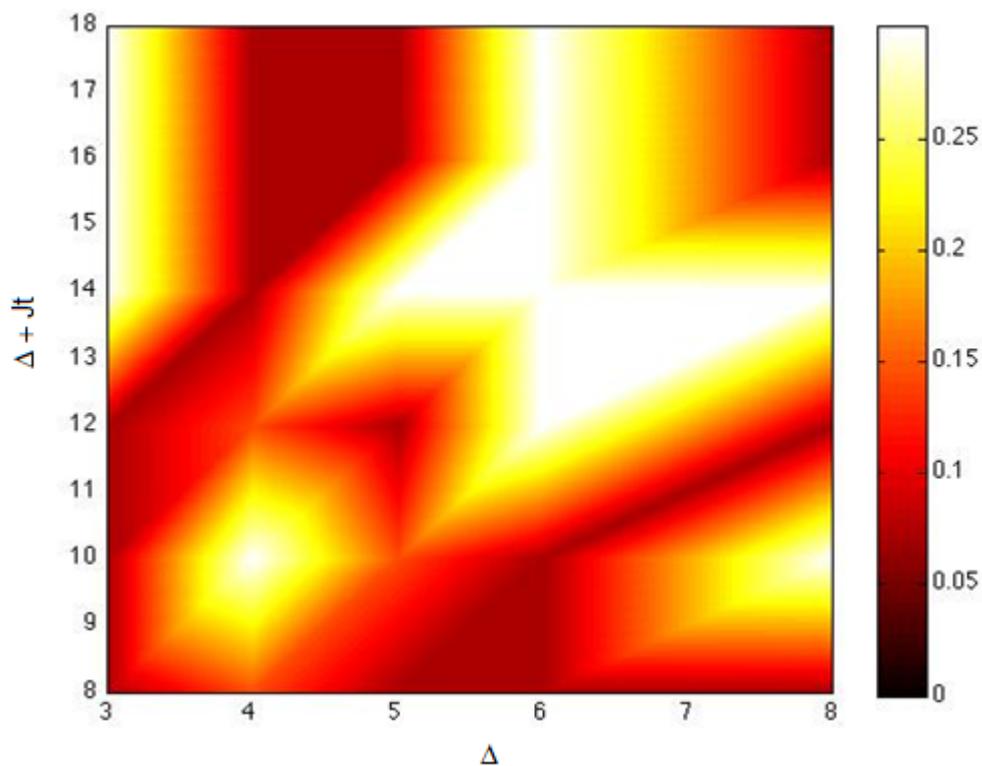


Figura 4.12 – Mapa de desempenho

O percentual de acerto da rede foi em média de 91%, o que se mostra bastante satisfatório para a classificação desse problema.