

## 7 Referências Bibliográficas

- [1] ABREU, R. L.; VILELA, L. C., *Serviços ancilares – Uma proposta de classificação e precificação para o setor elétrico brasileiro*, XVI SNPTEE, Campinas-SP, 2001.
- [2] AGUILERA, P. A.; FRENCH, G.; TORRES, J. A.; CASTRO, H.; VIDAL, J. L. M.; CANTON, M., *Application of the Kohonen Neural Network in Coastal Water Management: Methodological Development for the Assessment and Prediction of Water Quality*, *Wat. Res.*, vol. 35, n° 17, p. 4053-4062, 2001.
- [3] ALBERTSON, K.; AYLEN, J., *Forecasting the behaviour of manufacturing inventory*, *International Journal Forecasting* n° 19, p. 299-311, 2003.
- [4] ALBERTSON, K.; AYLEN, J., *Forecasting the behaviour of manufacturing inventory*, *International Journal of Forecasting* 19, p. 299-311, 2003.
- [5] BARROS, M.; SOUZA, R. C., *Regressão Dinâmica*, Núcleo de Estatística Computacional, PUC-Rio, 1995.
- [6] BEENSTOCK, M.; GOLDIN, E.; NABOT, D., *The demand for electricity in Israel*, *Energy Economics* 21, p. 168-183, 1999.
- [7] BENTZEN, J.; ENGSTED, T., *A revival of the autoregressive distributed lag model in estimating energy demand relationship*, *Energy* 26, p. 45-55, 2001.
- [8] BEZERRA, E. C., *Previsão da Potência Reativa da Carga*, Dissertação de Mestrado, PUC-Rio, Rio de Janeiro, 2002.
- [9] BEZERRA, U. H., *Previsão a curto-prazo de injeções de potências ativa e reativa por barra para aplicação em análise de segurança*, Tese de Doutorado, COPPE/UFRJ, Rio de Janeiro, 1988.

- [10] BHAGWAN, D.; PATVARDHAN, C., *Reactive Power dispatch with a hybrid stochastic search technique*, Electrical Power & Energy Systems, Article Press 2001.
- [11] BIRKES, D., DODGE, Y.; *Alternative Methods of Regression*, wiley series in probability and mathematical statistics, 1993.
- [12] BUNN, D. W., FARMER, E. D., *Comparative Models for Electrical Load Forecasting*, Chichester, John Willey & Sons, 1985.
- [13] CAMPOS, H., *Estatística experimental não-paramétrica*. 4 ed. Piracicaba: Departamento de Matemática e Estatística – ESALQ, 1983.
- [14] CARVIER, R.H.; NASH, J.G.. *Doing data Analysis with SPSS*. 2ªed. Thomson ISE, 2004.
- [15] CCPE, *Mapeamento das Incertezas e Construção dos Cenários do Mercado dos Cenários do Mercado de Energia Elétrica*, 2001.
- [16] CHO S.-B. , “*Self-Organizing Map with Dynamical Node Splitting: Application to Handwritten Digit Recognition*”, *Neural Computation*, 9, p.1345-1355, 1997.
- [17] CIVANLAR, S.; GRAINGER, J. J.; *Forecasting Distribution Feeder loads: Modeling and application to volt/var control*, *IEEE Transactions on Power Delivery*, vol. 3, Nº 1, p. 255-264, 1988.
- [18] DAÍ, Y.; NÍ, Y. X.; SHEN, C. M.; WEN, F. S.; HAN, Z. X.; WU, F. F., *A Study of reactive power marginal price in electricity market*, *Electric Power Systems Research* 57, p. 41-48, 2001.
- [19] DE CASTRO, L. N. & VON ZUBEN, F. J. An Improving Pruning Technique with Restart for the Kohonen Self-Organizing Feature Map, *Proc. Do IJCNN*, 3, p. 1916-1919, 1999a.
- [20] DE CASTRO, L. N. & VON ZUBEN, F. J., “*Neural Networks with Adaptive Activation Functions: A Second Order Approach*”, *Proc. do SCI/ISAS’99*, 3, p. 574-581, 1999b.
- [21] DE CASTRO, L. N., RAMÍREZ, L. A., GOMIDE, F. A. C. & VON ZUBEN, F. J., “*Hybrid Tuning of Activation Functions in Feedforward Networks*”, *Proc. do IJCNN’99*, 6, pp. 4263-4267, 1999.
- [22] DE CASTRO, L.N, VON ZUBEN, F.J., MARTINS, W.. *Hybrid and Constructive Learning Applied to a Prediction Problem in Agriculture*,

- Proceedings of the IEE WCCI'98, Anchorage-AK/USA, vol.3, pp. 1932-1926, 1998.
- [23] DEBELJAK, Z.; STRAPAC, M.; MEDIC-SARIC, M., *Application of self-organizing maps for the classification of chromatographic systems and prediction of values of chromatographic quantities*, Journal of Chromatography A, 925, p. 31-40, 2001.
- [24] DOUGLAS, A.P., BREIPOHL, A.M., LEE, F.N., ADAPA, R., *The Impacts of Temperature Forecast Uncertainty on Bayesian Load Forecasting*, IEEE Transactions on Power Systems, vol. 13, n° 4, november,1998.
- [25] DUARTE, A.; HOLDEN, K., *The business cycle in the G-7 economies*, International Journal of Forecasting 19, p. 685-700, 2003.
- [26] DURBIN, J., *Testing for Serial Correlation in Least-Square Regression when some of the regressors are lagged dependent variables*, in Econometrica 38, pp. 410-421, 1970.
- [27] EL-HAWARY, F.; MBAMALU, G. A. N., *Dynamic Heave Compensation using Robust Estimation Techniques*, Computers Elect. Engng. Vol. 22, n° 4 pp. 257-273, 1996.
- [28] EL-HAWARY, F.; MBAMALU, G. A. N., *Fair and Andrews's Weighting-Based IRWLS Algorithms for Time-Delay Estimation in Underwater Target Tracking*, IEEE Journal of Oceanic Engineering, vol. 18, n° 2, April, 1993.
- [29] EL-KEIB, A.A., MA, X., MA, H., *Advancement of Statistical based Modeling Techniques for Short-Term Load Forecasting*, Electric Power Systems Reseach, n° 35, 1995.
- [30] EL-SAYED, M. A. H., *Artificial neural network for reactive power optimization*, Neurocomputing 23, p. 255-263, 1998
- [31] EL-SHARKAWI, M.A., PENG, P., MARKS II, R.J., *Short-Term Peak Load Forecast using a Neuro-Fuzzy Model*, IEEE Transactions on Power Systems, vol. 14, n° 4, november, 1997.
- [32] FATAI, K.; OXLEY, L.; SCRIMGEOUR, F. G., *Modeling the causal relationship between energy consumption and GDP in New Zealand, Australia, India, Indonesia, the Philippines and Thailand*, Mathematics and Computers in Simulation, 2003.

- [33] FOX, J.; *Robust Regression*, Appendix to An R and S-PLUS Companion to Applied Regression, 2002.
- [34] FRITZKE, B.. “*Growing Cell Structures – A Self-Organizing Network for Unsupervised and Supervised Learning*”, Neural Networks, vol. 7, nº 9, p.1441-1460, 1994.
- [35] GARCIA-CERRUTTI, L. M., *Estimating elasticities of residential energy demand from panel county data using dynamic random variables models with heteroscedastic and correlated error terms*, Resource and Energy Economics 22, p. 355-366, 2000.
- [36] GUJARATI, D. N.; *Econometria Básica*, ed. Makron Books, 1996.
- [37] GUPTA, P. C., “*A Stochastic Approach to Peak Power-Demand Forecasting in Electric Utility Systems*”, IEEE Trans. on Power Apparatus and Systems, vol. 85, nº 11, pp.1144-1154, 1966.
- [38] GUPTA, P. C., “*Adaptative Short-Term Forecasting of Hourly Loads Using Weather Information*”, IEEE Trans., feb. 1972.
- [39] HAGAN, M.T., BEHR, S.M., *The Time Series Approach to Short Term Load Forecasting*, IEEE Transactions on Power Systems, vol. 2, nº 3, july,1987.
- [40] HAO, S.; PAPALEXOPOULOS, A., *Reactive Power Pricing and Management*, IEEE Transactions on Power Systems, February, p. 95-104, 1997.
- [41] HARVEY, A.C. and KOOPMAN, S.J., *Forecasting hourly electricity demand using time-varying splines*. Journal of the American Statistical Association 88, 1228 – 36, 1993.
- [42] HARVEY, A.C., *Forecasting, Structural Time Series Models and the Kalman Filter*.Cambridge University Press, Cambridge, 1989.
- [43] HAYKIN, S., *Redes Neurais Princípios e prática*, editora bookman 2ª ed.,Porto Alegre-RS, 1999.
- [44] HILL, C.; GRIFFITHS, W.; JUDGE, G., *Econometria*, ed. Saraiva, 1999.
- [45] HIPPERT, H., *Previsão de Cargas a Curto Prazo - Uma Avaliação de Viabilidade do Uso de Redes Neurais Artificiais*, Tese de Doutorado, PUC- Rio, Departamento de Engenharia Elétrica, março, 2001.
- [46] HOLLAND, P. W.; WELSCH, R. E., *Robust regression using iteratively reweighted least-square*. Commun. Statist. Theory A6, 813-827, 1977.

- [47] HSU, Y.Y., HO, K.L., *Fuzzy Expert Systems: an Application to Short-Term Load Forecasting*, IEE Proceedings-C, vol. 139, n o 6, november, 1992.
- [48] HSU, Y.Y., YANG, C.C., *Design of Artificial Neural Networks for Short-Term Load Forecasting. Part I: Self-Organizing Feature Maps for Day Type Identification*, IEE Proceedings-C, vol. 138, n° 5, september, 1991.
- [49] HSU, Y.Y., YANG, C.C., *Design of Artificial Neural Networks for Short-Term Load Forecasting. Part II: Multilayer Feedforward Networks for Peak Load and Valley Load Forecasting*, IEE Proceedings-C, vol. 138, n° 5, september, 1991.
- [50] HUANG, S.R., *Short-Term Load Forecasting Using Threshold Autoregressive Models*, IEE Proc-Gener Transm Distrib., vol.144, n° 5 477-481, 1997.
- [51] HUBER, P. J.; *Robust Statistics*, wiley series in probability and mathematical statistics, 1981.
- [52] JAIN, A. K.; DUIN, R. P. W.; MAO, J.; *Statistical Pattern Recognition: Review*, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 22, n° 1, January, 2000.
- [53] JARDINI, J. A.; CASOLARI, R. P., *Serviços Ancilares – Avaliação de benefícios e Custos no fornecimento de reativos em usinas hidroelétricas*, Relatório P&D, 2002.
- [54] JOHNSON, R. A.; WICHERN, D. W., *Applied Multivariate Statistical Analysis*, 4ª ed. Prentice Hall, New Jersey, 1998.
- [55] KIVIET, J. F.; DUFOUR, J. M., *Exact tests in single equation autoregressive distributed lag models*, Journal of Econometrics n° 80, p. 325-353, 1997.
- [56] KIVIET, J. F.; DUFOUR, J. M., *Exact tests in single equation autoregressive distributed lag models*, Journal of Econometrics 80, p. 325-353, 1997.
- [57] KHOTANZAD, A.; AFKHAMI-ROHANI, R.; LU, T.L.; DAVIS, M.H.; ABAYE, A; MARATUKULAM, D ``ANNSTLF- A Neural Network Based Electric Load Forecasting System," IEEE Trans. on Neural Networks, vol. 8, n° . 4, pp. 835-846, July 1997.

- [58] KHOTANZAD, A.; AFKHAMI-ROHANI, R.; MARATUKULAM, D. "ANNSTLF-Artificial Neural Network Short-Term Load Forecaster-Generation Three," IEEE Trans. on Power Systems, vol. 13, n°. 4, pp. 1413-1422, November 1998.
- [59] KOHONEN, T.. *Self-organizing maps*. Third Edition. Springer. 2000.
- [60] KOHONEN, T.; *An introduction to neural computing*, Neural Networks, vol. 1, p. 3-16, 1988a.
- [61] KOHONEN, T.; *Exploration of very large databases by self-organizing maps*, International Conference on Neural Networks, vol. I, p. PL1-PL6, 1997a.
- [62] KOHONEN, T.; *The self-organizing map*, Proceedings of the Institute of Electrical and Electronics Engineers, vol. 78, p. 1464-1480, 1990a.
- [63] KUZMIC, P.; HILL, C.; JANC, J. W.; *Practical Robust Fit of Enzyme Inhibition Data, Methods in Enzymology*, vol. 383, 2004.
- [64] KWOK, T. Y., & YEUNG, D. Y.. *Constructive Algorithms for Structure Learning in Feedforward Neural Networks for Regression Problems*, IEEE Trans. on Neural Networks, vol. 8, n° 3, p. 630-645, 1997.
- [65] LAMONT, W. L.; FU, J., *Cost Analysis of Reactive Power Support*, IEEE Transactions on Power Systems, August, p. 890-898, 1999.
- [66] LI, F.; BRYAN, U.; BALL, R., *Methods for Data Analysis in National Grid Company (UK) Reactive and Active Demand Research*, IEEE, p. 946-950, 1998.
- [67] LIMA, W. J. F.; FILHO, P. B., BEZERRA, U. H., *Nova Abordagem para Previsão de Carga Ativa e Reativa na Eletronorte*, XIV SNPTEE, Belém-PA, 1997.
- [68] LOURENÇO, P. M., *Um Modelo de Previsão de Curto Prazo de Carga Elétrica combinando Métodos Estatísticos e Inteligência Computacional*, Tese de Doutorado, PUC-Rio, Departamento de Engenharia Elétrica, junho, 1998.
- [69] MATOS, O. C.; *Econometria Básica*, ed. Atlas, 1997.
- [70] MBAMALU, G. A. N.; EL-HAWARY, F., *Load Forecasting via suboptimal seasonal autoregressive models and Iteratively Reweighted Least Squares Estimation*, IEEE Transactions on Power Systems, vol. 8, n° 1, February 1993.

- [71] MCCULLOCH W. & PITTS W.. *A Logical Calculus of the Ideas Immanent in Nervous Activity*, Bulletin of Mathematical Biophysics, 5, p. 115-133, 1943.
- [72] MENDES, B. V. M, DUARTE, A. M. - *Modelos Estatísticos Aplicados ao Mercado Financeiro Brasileiro*. 13º SINAPE. ABE – ASSOCIAÇÃO BRASILEIRA DE ESTATÍSTICA, 1998.
- [73] MILI, L.; STEENO, G.; DOBRACA, F.; FRENCH, D.; *A Robust Estimation for Topology Error Identification*, IEEE Transactions on Power Systems, vol. 14, nº 4, November, 1999.
- [74] MORNOH, J. A.; ZHU, J., *Multiple indices for optimal reactive power pricing and control*, Decision Support Systems 24, p.223-232, 1999.
- [75] NETER, J.; KUTNER, M.; NACHTSHEIM, C.; WASSERMAN, W., *Applied Linear Statistical Models*. McGraw-Hill, 1996.
- [76] NETO, L.S.R.; VELLASCO, M.M.; PACHECO, M.A.; ZEBULUM, R. *Very Short Term Load Forecasting System Using Neural Networks*, The Seventeenth Annual International Symposium on Forecasting, pp. 51, Barbados, 19-21 de Junho de 1997.
- [77] RAMANATHAN, R.; ENGLE, R.; GRANGER, C.W.J.; ARAGHI, F.V.; BRACE, C.; *Short-run forecasts of electricity loads and peaks*, International Journal of Forecasting 13, p.161-174, 1997.
- [78] SADOWNIK, R., BARBOSA, E.P., *Short-Term Load Forecasting of Industrial Electricity Consumption Brazil*, Journal of Forecasting, vol. 18, 1999.
- [79] SHARIF, S. S.; TAYLOR, J. H.; HILL, E. F., *On-line Optimal Reactive Power Flow by Energy Loss Minimization*, proceeding of the 35<sup>th</sup>, IEEE, Kobe-Japan, 1996.
- [80] SILVA, E. L., *O provimento de potência reativa como um serviço ancilar*, XV SNPTEE, Foz do Iguaçu-PR, 1999.
- [81] SILVA, H.F., *Um Sistema Integrado de Monitoração e Previsão de Carga Elétrica de Curto Prazo*, Tese de Doutorado, PUC-Rio, Departamento de Engenharia Elétrica, abril, 2001.
- [82] SONG, H.; WITT, S. F.; JENSEN, T. C., *Tourism Forecasting: accuracy of alternative econometric models*, International Journal Forecasting nº 19, p. 123-141, 2003.

- [83] SONG, H.; WITT, S. F.; JENSEN, T. C., *Tourism forecasting: accuracy of alternative econometric models*, International Journal of Forecasting 19, p. 123-141, 2003.
- [84] SONG, H.; WONG, K. K. F.; CHON, K. K. S., *Modelling and forecasting the demand for Hong Kong tourism*, International Journal of Hospitality Management, 2003.
- [85] SOUZA, R. C.; VASCONCELLOS, K. L. P., *Análise de Regressão Simples, Múltipla e Stepwise*, Núcleo de Estatística Computacional, PUC-Rio, 1995.
- [86] SOUZA, R. C.; CHRISTO, E. S.; MEDEIROS, L.; LESSA, M.L.; SALESSE, V.A.; Metodologia para Estimção e Previsão dos Perfis das Curvas de Carga por Subestação e Classes de Consumo. II CITENEL, p. 693-698, Salvador, 2003.
- [87] TANG, T. C., *Japanese aggregate import demand function reassessment from the 'bounds' testing approach*, Japan and the World Economy 15, p. 419-436, 2003.
- [88] VELASCO, C. J., *Modelos Estocásticos para Previsão de Potência Reativa: Um Estudo*, Dissertação de Mestrado, COPPE/UFRJ, Rio de Janeiro, 1981.
- [89] WARNER, B. A.; MISRA, M.; *Iteratively Reweighted Least Square based Learning*, IEEE, 1998.
- [90] YANG, H.T.; HUANG, C.M.; HUANG, C.L., *Identification of ARMAX Model for Short Term Electrical Load Forecasting: An Evolutionary Programming Approach*, IEEE Transactions on Power Systems, vol. 11, nº 1, february, 1996.
- [91] YU, Z., *A Temperature Match based Optimization Method for Daily Load Prediction considering DLC Effect*, IEEE Transactions on Power Systems, vol. 11, nº 2, may, 1996.
- [92] ZANINI, A., *Regulação Econômica No Setor Elétrico Brasileiro: Uma Metodologia Para Definição De Fronteiras De Eficiência E Cálculo Do Fator X Para Empresas Distribuidoras De Energia Elétrica*, Tese de Doutorado, Departamento de Engenharia Elétrica, PUC-RJ, Rio de Janeiro, 2004.



- [93] ZANINI, A.; SOUZA, R. C.; PEDREIRA, C. E., *Um Modelo Híbrido para previsão de curto prazo da demanda de gasolina automotiva no Brasil*, Proceedings of the V Brazilian Conference on Neural Networks – V Congresso Brasileiro de Redes Neurais, p. 403-407, Rio de Janeiro, RJ, 2001.

## 8 Anexos – Redes Neurais Artificiais

A motivação original desta metodologia foi a tentativa de modelar a rede de neurônios humanos visando compreender o funcionamento do cérebro. Portanto, como o próprio nome da metodologia revela, sua motivação inicial foi a de realizar tarefas complexas que o cérebro executa com elevada efetividade (por exemplo: reconhecimento de padrões, percepção e controle motor) através da simulação de seu funcionamento.

Segundo Haykin (1999), uma rede neural artificial (RNA) é um sistema de processamento maciçamente paralelo, composto por unidades simples com capacidade natural de armazenar conhecimento e disponibilizá-lo para uso futuro.

Do ponto de vista neurofisiológico, muito pouco se conhece sobre o funcionamento dos neurônios e suas conexões o que compromete a fidelidade destes modelos em fisiologia. As RNAs assemelham-se ao cérebro em dois aspectos:

- Elas extraem conhecimento do ambiente através de um processo de aprendizagem ou treinamento; e
- Os pesos das conexões entre os neurônios, conhecidos como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.

A figura 24 apresenta um modelo de neurônio biológico com a seqüência de propagação dos sinais pela célula. Os neurônios artificiais também são chamados de nós, ou unidades.

A natureza das RNAs faz com que seu estudo seja multidisciplinar, envolvendo pesquisadores de diversas áreas, como neurofisiologia, psicologia, física, computação, engenharia, estatística, entre outras.




Figura 24 – Célula Neural Biológica

McCulloch & Pitts (1943) projetaram a estrutura que é conhecida como a unidade básica de uma rede neural. Estes pesquisadores propuseram um modelo de neurônio como uma unidade de processamento binária (Figura 25) e provaram que estas unidades são capazes de executar várias operações lógicas (OU, AND, etc.). Este modelo, apesar de muito simples, trouxe uma grande contribuição para as discussões sobre a construção dos primeiros computadores digitais, permitindo a criação dos primeiros modelos matemáticos de dispositivos artificiais que buscavam analogias biológicas. Matematicamente, o neurônio da Figura 25 pode ser expresso por:

$$y = f(w_0 \cdot x_0 + w_1 \cdot x_1 + \dots + w_n \cdot x_n - b)$$

onde o termo  $b$  é chamado de “bias” (ruído somados aos dados). Alterando - o, provoca-se uma translação da função de ativação ao longo do eixo das ordenadas, permitindo, então, uma maior variação do valor de resposta do neurônio artificial.

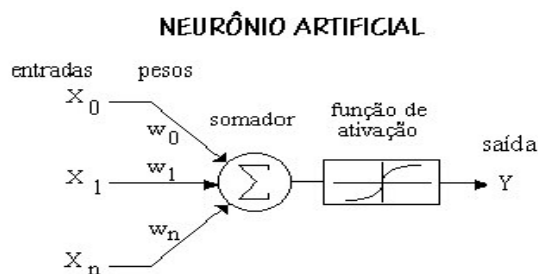


Figura 25 – Representação funcional de um neurônio artificial

## 8.1. Redes Feedforward

No caso mais simples de redes em camadas (*layers*), tem-se uma camada de entrada com neurônios cujas saídas alimentam a última camada da rede. Geralmente, os neurônios de entrada são propagadores puros, ou seja, eles simplesmente repetem o sinal de entrada em sua saída distribuída. Por outro lado, as unidades de saída costumam ser unidades processadoras, como apresentado na Figura 26. A propagação de sinais nesta rede é puramente unidirecional (*feedforward*): os sinais são propagados apenas da entrada para a saída, e nunca vice-versa. Esta arquitetura está ilustrada na Figura 26(a) e a direção de propagação dos sinais na Figura 26(b).

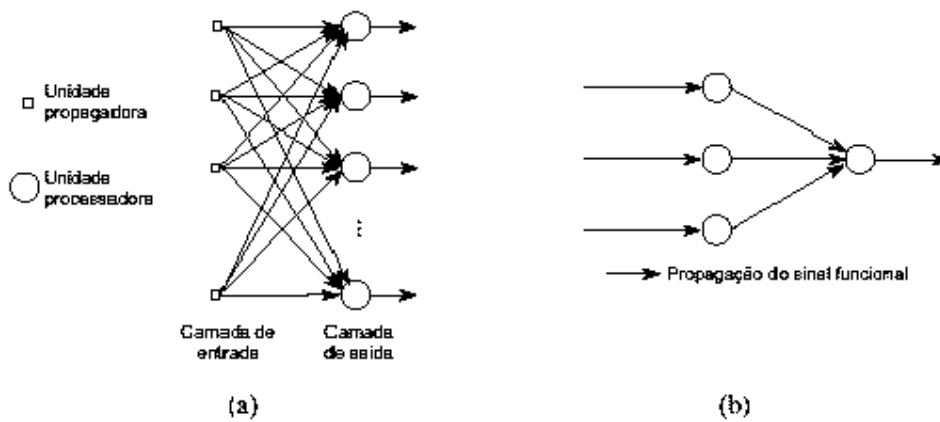


Figura 26 – Redes Neurais *Feedforward* camada única. a) Arquitetura; b) Sentido de propagação do sinal funcional.

A segunda classe de rede *feedforward* se distingue pela presença de uma ou mais camadas intermediárias ou escondidas (camadas em que os neurônios são efetivamente unidades processadoras, mas não correspondem à camada de saída). Adicionando-se uma ou mais camadas intermediárias, aumenta-se o poder computacional de processamento não-linear e armazenagem da rede. O conjunto de saídas dos neurônios de cada camada da rede é utilizada como entrada para a camada seguinte. A Figura 27(a) ilustra uma rede *feedforward* de múltiplas (duas) camadas intermediárias.

As redes *feedforward* de múltiplas camadas, são geralmente treinadas usando o algoritmo de retro-propagação do erro (*error backpropagation*), embora existam outros algoritmos de treinamento. Este algoritmo requer a propagação direta (*feedforward*) do sinal de entrada através da rede, e a retro-propagação (propagação reversa, ou *backpropagation*) do sinal de erro, como ilustrado na Figura 27(b).

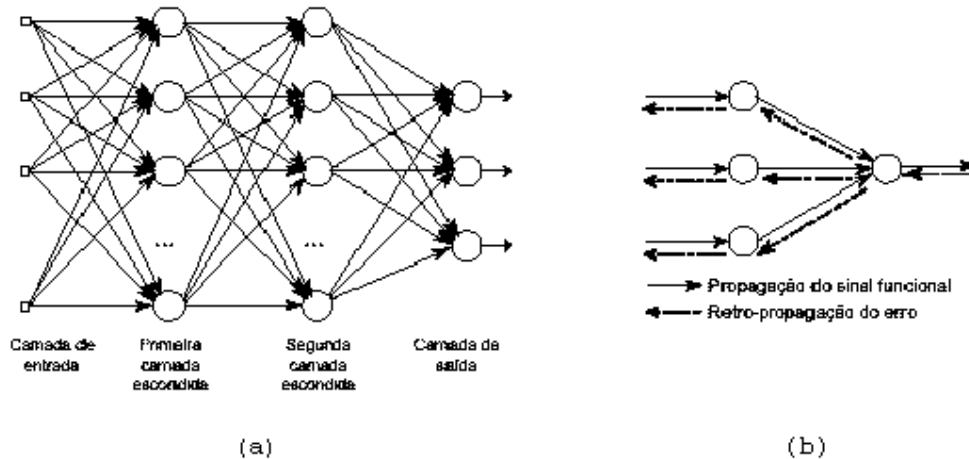


Figura 27- Redes Neurais *Feedforward* múltiplas camadas a) Arquitetura; b) Sentido de propagação do sinal funcional.

## 8.2. Métodos de Aprendizagem

A capacidade de aprendizagem é uma das características marcantes das RNAs. Uma rede neural aprende, basicamente, através de um processo iterativo de ajuste de pesos e limiares (bias). Atualmente, existem processos mais sofisticados de aprendizagem (ou treinamento), que são capazes de ajustar não apenas os pesos da rede, mas também sua arquitetura e as funções de ativação dos neurônios (Kwok & Yeung, 1997, de Castro et al., 1999a,b; de Castro & Von Zuben, 1998).

Segundo Haykin (1999), Aprendizagem (ou treinamento) é o processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um mecanismo de apresentação de estímulos fornecidos pelo ambiente no qual a rede está inserida. O tipo de treinamento é definido pela forma na qual os parâmetros são modificados.

Resumidamente, podemos descrever o funcionamento de um neurônio artificial como:

Na primeira etapa, os sinais de entrada são multiplicados por seus respectivos pesos ou sinapses;

Na segunda etapa estes resultados são somados pela função somadora;

Na última etapa, aplica-se a função de ativação ao resultado da função somadora, gerando, então, a saída do neurônio.

### **8.2.1. Aprendizagem Supervisionada**

Um treinamento supervisionado implica na apresentação de vários vetores de entrada e saída correspondentes aos valores desejados, até que o erro alcance um nível satisfatório, dentre os algoritmos de treinamento supervisionado encontramos o de retropropagação dos erros (“backpropagation”). O treinamento não-supervisionado não requer este vetor de saída; o sistema extrai as características do conjunto de padrões, agrupando-os em classes. Desta forma, o treinamento não-supervisionado se aplica apenas a problemas de agrupamentos e otimização, enquanto o treinamento supervisionado é mais genérico, podendo ser empregado em previsões de séries temporais.

### **8.2.2. Aprendizagem Não-Supervisionada**

No processo de aprendizagem não-supervisionada ou auto-organizada, não existe um supervisor para avaliar o desempenho da rede em relação ao conjunto de treinamento, ou seja, os dados são não-rotulados. A rede se adapta às regularidades estatísticas dos dados de entrada, desenvolvendo a habilidade de criar representações internas para codificar características da entrada e, assim, gerar novas classes automaticamente. Geralmente os algoritmos auto-organizados utilizam aprendizagem competitiva.

Na aprendizagem competitiva, os neurônios de saída da rede competem entre si para se tornarem ativos. Um único neurônio de saída é ativado a cada iteração. Esta característica torna o algoritmo apropriado para descobrir

características estatísticas, que podem ser utilizadas para classificar um conjunto de padrões de entrada.

Existem três elementos básicos para uma regra de aprendizagem competitiva:

- Um conjunto de neurônios iguais, exceto pelos pesos das conexões;
- Um mecanismo de competição entre os neurônios. Aquele que vencer a competição é chamado de vencedor (*winner-takes-all*).

Neurônios individuais aprendem a se especializar em grupos (ou clusters) de padrões similares, tornando-se detectores de características para diferentes classes de padrões de entrada.

Em sua forma mais simples, uma rede competitiva possui uma única camada de neurônios de saída, totalmente interconectados. Também existem conexões laterais entre os neurônios capazes de efetuar uma inibição lateral entre os neurônios vizinhos.

Para um neurônio  $k$  ser o vencedor, seu campo induzido local  $v_k$  em relação a um determinado padrão  $x$  deve ser o maior de toda a rede. O sinal de saída  $y_k$  do neurônio vencedor  $k$  é posto em 1, e o sinal de saída de todos os outros neurônios que perderam a competição é posto em 0.

$$y_k(t) = \begin{cases} 1 & \text{se } v_k > v_j, \forall j, j \neq k \\ 0 & \text{demais casos} \end{cases}$$

onde o campo induzido local  $v_k$  representa a ação combinada das entradas positivas e laterais do neurônio.

Se um neurônio não responde a um determinado padrão de entrada, nenhuma aprendizagem ocorre. Por outro lado, se um neurônio ganha a competição, um ajuste  $\Delta w_{k,j}$  é aplicado ao vetor de pesos  $w_{k,j}$  deste neurônio vencedor.