

PREDIÇÃO DA DINÂMICA DE LASERS DE PONTOS QUÂNTICOS SEMICONDUTORES UTILIZANDO MÁQUINAS DE APRENDIZADO EXTREMO

WILD F.S.SANTOS, EDUARDO F. SIMAS FILHO

Laboratório de Sistemas Digitais - PPGEE / Universidade Federal da Bahia
E-mail: wild.freitas@hotmail.com, eduardo.simas@ufba.br

GEORGE A.P. THÉ

Programa da Pós-graduação em Engenharia de Teleinformática - PPGETI / Universidade Federal do Ceará
E-mails: george.the@ufc.br

Abstract— The class of quantum dot lasers is an alternative to quantum well lasers, so an important part of their development as technology is the modeling approach, which requires the use of effective methods to incorporate various physical phenomena present in actual devices. This article shows the results obtained with MATLAB implementation, for the behavior of the optical output power in real quantum dot lasers using the extreme machine learning technique.

Keywords— quantum dots laser, extreme learning machine, nonlinear autoregressive exogenous model, simulator.

Resumo— A classe de lasers de pontos quânticos se apresenta como alternativa aos lasers de poços quânticos, logo uma parte importante para seu desenvolvimento como tecnologia é a modelagem de dispositivos, requerendo o uso de métodos eficazes capazes de incorporar vários fenômenos físicos presentes em dispositivos reais. Este artigo mostra os resultados obtidos, com implementação em MATLAB, do comportamento da potência de saída ótica dos lasers de pontos quânticos utilizando a técnica de máquina de aprendizado extremo.

Palavras-chave— Laser de pontos quânticos, máquina de aprendizado extremo, modelagem não linear autoregressiva exógena, simulador.

1 Introdução

Laser de pontos quânticos semicondutores é uma recente classe de dispositivos que se apresenta como alternativa aos lasers de poços quânticos. Durante o desenvolvimento de uma nova fonte de laser, um passo importante consiste na modelagem dos dispositivos a serem construídos. Isto requer o uso de bons métodos, capazes de incorporar os efeitos causados por vários dos fenômenos físicos presentes em dispositivos reais, permitindo que o modelo desenvolvido auxilie na interpretação de resultados experimentais e/ou na sua previsão.

Tradicionalmente, a comunidade científica trata o problema da modelagem de lasers de pontos quânticos a partir de duas principais vertentes a saber: o modelo baseado em descrição de microestados (Grundmann et al., 1997) e o modelo baseado em equações de taxa (Sugawara et al., 2005). Embora leve a resultados mais precisos em termos de capacidade de predição, o primeiro tipo envolve uma descrição que recai na mecânica quântica, sendo, portanto, preferido entre a comunidade de físicos. A segunda abordagem, por outro lado, é substancialmente mais simples e intuitiva, pois consiste numa descrição de dinâmica de populações, sendo mais adequada para a comunidade de engenheiros e experimentalistas.

O inconveniente desta segunda abordagem recai justamente na capacidade de reproduzir resultados ou

de prever comportamentos. Uma vez que isto é indispensável para, por exemplo, realizar procedimentos de extração de parâmetros, auxiliar no projeto de dispositivos, ou mesmo em ferramentas de simulação assistida em ambiente CAD, na prática o que se faz é aprimorar a descrição do sistema físico mediante o aumento do número de equações de estado que descrevem o dispositivo (Thé 2010). Inevitavelmente, isto leva a um significativo aumento do esforço computacional nas tarefas de estudo numérico de desempenho do laser, o que dificulta sobremaneira a obtenção de resultados confiáveis em tempos breves.

Justamente nesse contexto o presente trabalho encontra espaço, a busca por modelos alternativos de aprendizado de máquina capazes de reproduzir e/ou prever as características de desempenho de lasers de pontos quânticos em operação contínua e pulsada.

Uma alternativa a se buscar neste contexto, é a adoção de modelos que bem representassem a dinâmica não-linear existente na resposta destes dispositivos a entrada em degrau e impulso, de tal modo que seu comportamento temporal pudesse ser previsto. Isto seria importante porque a curva P-I poderia ser simulada, além do que, as características dinâmicas de desempenho (sobressinal, tempo de acomodação, fator de amortecimento, etc....) poderiam ser estimadas, juntamente com as características dos pulsos (largura a meia-altura, potência de pico, taxa de supressão), em caso de investigação de operação pulsada. Em outras palavras, isto significa fazer a identificação do sistema laser a partir de amostras de entrada e saída, as quais

são respectivamente entendidas, em primeira aproximação, como a corrente elétrica injetada no dispositivo, e a potência ótica resultante na cavidade.

A consideração acima implica conceber o laser sob acionamento direto como um sistema de entrada única e saída única (SISO - *Single Input - Single Output*), que pode ser bem descrito em tempo discreto pelo modelo NARX (*Nonlinear AutoRegressive models with eXogenous inputs*), um mapeamento não-linear que utiliza como entradas os valores atuais e passados do sinal de entrada e os valores atrasados do sinal de saída, produzindo uma estimativa da saída atual do sistema (Alazrai e Lee, 2012). Uma abordagem para a estimação da não-linearidade do modelo NARX é utilizar uma rede neural e, mais especificamente, no presente trabalho, foi investigada utilização do tipo ELM (*Extreme Learning Machine* – ou Máquina de Aprendizado Extremo).

2 Fundamentação teórica

2.1 Modelagem de Lasers semicondutores

Lasers semicondutores realizados com pontos quânticos auto-organizáveis oferecem características superiores se comparados aos tradicionais dispositivos de poços quânticos, tais como reduzida corrente de limiar e grande largura de banda (Rafailov et al., 2007, Bimberg e Ledentsov, 2003). Também tem importantes aplicações como lasers de alta potência (Krakowski et al., 2006), como geradores de pulsos óticos a partir de *q-switching* e *mode-locking* (Summers et al., 2007, Rafailov et al., 2005). A possibilidade de emissão a partir dos portadores de ambos os estados confinados (fundamental e primeiro estado excitado) permite, ainda, a obtenção de fontes de banda larga (além de 75 nm) (Djie et al., 2007).

Para analisar e auxiliar o projeto de fontes laser que tenha pontos quânticos na região ativa, é indispensável a construção de modelos numéricos eficientes, seja do ponto de vista da descrição da riqueza intrínseca dos processos físicos envolvidos, seja do ponto de vista do esforço computacional. Neste sentido, de um lado estão os modelos de *master-equations*, em que os processos de *scattering* (captura, relaxamento, etc....) e de recombinação são incluídos a partir de uma descrição de microestados (Grundmann et al., 1997), enquanto do outro lado encontram-se os modelos de equações de taxa, em que os processos de *scattering* e recombinação são considerados a partir de tempos médios entre eventos (Thé 2009), de mais fácil compreensão, e adotado pela maioria da comunidade científica em sua versão de multipopulações.

Para um laser de pontos quânticos, a abordagem de multipopulações consiste, essencialmente, em separar a população total de pontos quânticos de um dispositivo em vários grupos menores, cada qual composta por pontos quânticos de propriedades espectrais similares. Este procedimento tem estreita relação com o espectro de fotoluminescência destes dispositivos, que revelam alargamentos em torno das linhas de

emissão de estado fundamental, bem como de primeiro e segundo estados-excitados. Ao proceder com o referido agrupamento, o que se está fazendo é uma amostragem do espectro de emissão do laser e uma atribuição de cada raia espectral a um dado grupo de pontos quânticos.

Dentre os modelos de multipopulações já reportados na literatura, os mais eficientes contemplam uma enormidade de condições e/ou parâmetros (Thé 2012), tais como o alargamento homogêneo devido ao tempo de *dephasing* excitônico (Sugawara et al., 2005), mecanismos de captura direta (Nielsen et al., 2004), a existência do segundo estado excitado (Drzewietzki 2010), a existência de dinâmica distinta entre elétrons e lacunas (Viktorov et al., 2005). Isto tem sido possível, entretanto, as custas de muito esforço computacional no cálculo das soluções dinâmicas de operação em modo contínuo e modo pulsado, o que aponta para a necessidade de novos modelos.

2.2 NARX (*Nonlinear AutoRegressive models with eXogenous inputs*)

O modelo NARX (Alazrai e Lee, 2012) consiste em um mapeamento não-linear que utiliza como entradas os valores atuais e passados do sinal de entrada (usualmente chamado de entrada exógena) e os valores atrasados do sinal de saída (geralmente chamados de sinais regressivos), produzindo uma estimativa da saída atual do sistema.

A expressão abaixo apresenta o modelo NARX para um sistema de entrada única e saída única:

$$y(k) = \phi[y(k-1), \dots, y(k-n); u(k), \dots, u(k-m+1)] \quad (1)$$

em que $u(k)$ e $y(k)$ representam os valores de entrada e saída, respectivamente, do sistema no instante k , ao passo que m e n representam a ordem da entrada e da saída, e ϕ representa a função de mapeamento não-linear.

2.3 ELM (*Extreme Learning Machine*)

Uma abordagem para a estimação da não-linearidade do modelo NARX é utilizar uma rede neural artificial (RNA), onde no trabalho em questão, foi utilizado uma arquitetura de rede supervisionada mais recentemente desenvolvida, a ELM (Huang et al., 2006), que é uma técnica de aprendizado para treinamento de redes neurais *feedforward* de única camada oculta (*Single Hidden Layer Feedforward Neural Networks* – SLFNs) e que aumenta a velocidade de aprendizado através da geração aleatória dos pesos de entrada e dos *bias* da camada oculta (Pacífico e Ludemir, 2012).

Segundo Huang e Chen (2007), o ELM foi proposto como um SLFN “generalizado” com a seguinte função de saída:

$$f_L(x) = \sum_{i=1}^L \beta_i h_i(x) = \mathbf{h}(x)\boldsymbol{\beta} \quad (2)$$

onde $\beta = [\beta_1, \dots, \beta_L]^T$ é o vetor peso de saída entre a camada oculta com L nós até $m \geq 1$ nós de saída, e $\mathbf{h}(x) = [h_1(x), \dots, h_L(x)]$ é a função não-linear de mapeamento, por exemplo, a saída do vetor da camada oculta em relação a entrada x , $h_i(x)$ é a saída do i -ésimo nó oculto de saída. As funções de saída dos nós ocultos podem não ser únicas. Diferentes funções de saída podem ser utilizadas em diferentes neurônios ocultos. A real aplicação de $h_i(x)$ pode ser dada por:

$$h_i(x) = G(a_i, b_i, x), \quad a_i \in R^d, b_i \in R \quad (3)$$

onde $G(a, b, x)$ (com os parâmetros de nós escondidos (a, b)) é uma função contínua não-linear.

Segundo Huang et al. (2014), o algoritmo ELM treina a SLFN em duas fases principais: a primeira relacionada ao mapeamento aleatório das características e a segunda sobre a solução linear dos parâmetros. Na primeira etapa, a ELM inicializa aleatoriamente a camada escondida para mapear os dados de entrada em um espaço de características através de algumas funções de mapeamento não-lineares, podendo ser qualquer função contínua não-linear (Gaussiana, Multi-quadrática, tangente hiperbólica, etc....).

Os parâmetros dos nós ocultos da ELM são aleatoriamente gerados, independentemente do treinamento de dados iniciais, através de qualquer distribuição contínua de probabilidade, ao invés de ser explicitamente treinados levando a uma eficiência notável em comparação a demais redes neurais tradicionais. Na segunda etapa, os pesos são relacionados à camada oculta e a camada de saída, indicado por β , e são resolvidos pela diminuição do erro de aproximação observando o erro quadrático, como descrito na equação abaixo:

$$\beta \in R^{L \times m \min ||H\beta - T||^2} \quad (4)$$

onde H é a matriz de saída da camada oculta (gerada aleatoriamente) e T é a matriz de dados de treinamento e $|| \cdot ||$ é o método de Frobenius.

A solução ótima da equação (4) pode ser encontrada da seguinte forma:

$$\beta^* = H^\dagger T \quad (5)$$

onde $H^\dagger$ denota a matriz inversa generalizada Moore-Penrose de H .

Porém um detalhe importante desta técnica, ressaltada por Cao et al. (2012), é que apesar da rede oferecer uma boa capacidade de generalização, a escolha aleatória dos pesos sinápticos da camada oculta (pesos de entrada) pode gerar um conjunto não-ótimo de pesos e limiares, ocasionando o efeito de sobreajuste.

Outra limitação observada é a escolha do número de neurônios ocultos e a possibilidade de diminuí-los sem afetar a eficácia do aprendizado, acarretando em diversos testes por tentativa e erro (Yang et al., 2012).

3 Metodologia

Para este trabalho, foram utilizadas as medições realizadas pelo *Semiconductor Optics Group da Technical University of Darmstadt* (Alemanha); consistem na potência óptica de saída filtrada no entorno do comprimento de onda da emissão do estado fundamental, para uma temperatura de operação de 40°C e em resposta a excitações do tipo injeção degrau de corrente.

A resposta a cada excitação constitui, do ponto de vista da modelagem, uma série temporal que, no experimento de aquisição realizado, possui 510 amostras. No total são 71 excitações de corrente, sendo a menor 115 mA e, a maior 185 mA (com intervalos de 1 mA).

Assim, com os dados de potência e corrente normalizados, para evitar eventuais distorções nas simulações, foi implementado no MATLAB um algoritmo simulando a modelagem similar ao NARX, porém devido a limitações do algoritmo do ELM clássico, foi utilizado para a autoregressão os valores de potência medidos, e não os valores de saída do ELM, resultando na seguinte equação de modelagem:

$$P_{ELM}(n) = \phi[P_{real}(n-1), \dots, P_{real}(n-k); I(n)] \quad (6)$$

onde $P_{ELM}(n)$ é a potência óptica simulada no instante n pelo ELM, $P_{real}(n)$ é a potência óptica real (medida) no instante (n) , ϕ representa a não linearidade do modelo desempenhado pelo ELM, e $I(n)$ é a corrente de entrada no instante (n) , observando-se que não foi considerado os valores da corrente nos instantes anteriores a (n) devido a sua função ser um degrau constante em todo o período do experimento.

Para uma melhor compreensão, a modelagem retratada na equação (6) está ilustrada na Figura 1 abaixo:




Figura 1 - Modelagem com ELM

Com a finalidade de alcançar o menor erro possível, sem um grande custo computacional, foram realizadas diversas simulações alterando os seguintes aspectos: a quantidade de neurônios ocultos do ELM (5, 10 e 15), quantidade de dados para o treinamento do ELM (10%, 20% e 30% dos dados, considerando o comportamento de toda a série temporal, e variando uniformemente a corrente a cada série temporal escolhida) e variando o k da equação (6) (fazendo $k=4$ e $k=5$), ou seja, utilizando as últimas 4 ou 5 potências óticas medidas na predição da potência de saída do ELM.

Vale ressaltar que para a avaliação dos resultados descritos abaixo, foi considerado o melhor resultado




Figura 2 – Potências Óticas Medidas Normalizadas

obtido para cada modelagem em um universo de 100 simulações e que a função seno foi utilizada para a inicialização do ELM, podendo-se obter diferentes resultados com diferentes funções de inicialização

4 Resultados

Com as diversas modelagens descritas acima, os melhores resultados alcançados em relação ao erro quadrático médio estão ilustrados nas Tabelas 1 e 2 (máximo em vermelho e mínimo em azul), onde pode-se visualizar a melhora do desempenho do modelo com o incremento de neurônios, quantidade de amostras utilizadas para o treinamento e aumento no número de potências óticas medidas na entrada no ELM.

Tabela 1 – Erro Médio Quadrático (adimensional) para $k = 4$

Neurônios		5	10	15
% de Treinamento	10%	0,010513	0,010299	0,010256
	20%	0,011346	0,010311	0,010260
	30%	0,010961	0,010306	0,010256

Tabela 2 – Erro Médio Quadrático (adimensional) para $k = 5$

Neurônios		5	10	15
% de Treinamento	10%	0,010879	0,010421	0,010216
	20%	0,011697	0,010342	0,010183
	30%	0,010813	0,010361	0,010194

Porém, observa-se através das Tabelas 1 e 2, que o menor erro médio quadrático obtido foi utilizando 20% das amostras, com 15 neurônios na camada oculta do ELM e com $k = 5$, em detrimento ao esperado, pois foi superior à modelagem utilizando uma maior quantidade de dados para o treinamento.

O mesmo ocorreu para o pior caso, que ao contrário do esperado, não foi o modelo mais simples, que

utiliza 10% das amostras, com 5 neurônios ocultos e $k = 4$, e sim um modelo “intermediário” que utilizou 20% das amostras, com 5 neurônios ocultos e $k = 5$.

A Figura 2 ilustra as potências óticas medidas no experimento (normalizadas) ao longo do tempo e com a variação da corrente de entrada (série temporal), demonstrando o comportamento não linear do laser, tanto em relação a sua curva de variação da saída ao longo do tempo, quanto o valor final obtido.

Estas duas características são uma das possíveis explicações para os resultados obtidos não serem condizentes com o esperado e, sendo assim, crucial para o bom desempenho do modelo uma amostragem de treinamento que capture adequadamente este comportamento.

Para facilitar a comparação entre as séries temporais, individualmente, e visualizar mais nitidamente a variação de seu comportamento ao longo do tempo, variando a corrente, foram feitas as seguintes comparações gráficas nas Figuras 3 e 4, onde é possível visualizar os resultados obtidos pela modelagem (vermelho) e os resultados esperado (azul), e assim, constatar o resultado satisfatório da modelagem:




Figura 3 - Série temporal com $I = 125\text{mA}$




Figura 5 - Gráfico Candlestick dos erros absolutos para $k = 5$, com 20% das amostras e 15 neurônios




Figura 4 - Série temporal com $I=175\text{mA}$

Outra análise comparativa para visualizar o comportamento do erro ao longo das séries temporais foi feita através do cálculo do erro absoluto médio (Tabelas 3 e 4) e do erro absoluto máximo (Tabelas 5 e 6), onde em ambas as tabelas, os valores máximos estão destacados em vermelho e os valores mínimos em azul. E adicionalmente, o gráfico candlestick (Figura 5), que demonstra visualmente o comportamento do erro absoluto nas diferentes séries temporais, com destaque os erros absolutos máximos (marcadores em vermelho) e erros médios (faixas em azul).

Tabela 3 - Erro Absoluto Médio (adimensional) para $k = 4$

Neurônios		5	10	15
% de Treinamento	10%	0,00902	0,00877	0,00872
	20%	0,00982	0,00880	0,00871
	30%	0,00936	0,00878	0,00873

Tabela 4 - Erro Absoluto Médio (adimensional) para $k = 5$

Neurônios		5	10	15
% de Treinamento	10%	0,00923	0,00895	0,00861
	20%	0,01035	0,00888	0,00989
	30%	0,00942	0,00885	0,00865

Tabela 5 - Erro Absoluto Máximo (adimensional) para $k = 4$

Neurônios		5	10	15
% de Treinamento	10%	0,06233	0,05854	0,05716
	20%	0,06647	0,05856	0,05708
	30%	0,06239	0,05793	0,05688

Tabela 6 - Erro Absoluto Máximo (adimensional) para $k = 5$

Neurônios		5	10	15
% de Treinamento	10%	0,05883	0,06052	0,05369
	20%	0,06915	0,05887	0,06586
	30%	0,06610	0,05566	0,05410

Assim, é possível visualizar nas Tabelas 3, 4, 5 e 6, que em relação ao pior caso, ambas as análises, pelo erro médio quadrático e pelo erro absoluto médio e máximo, obtiveram o mesmo resultado.

Porém, a modelagem de melhor resultado em relação ao erro absoluto, tanto médio quanto máximo, foi a modelagem com $k = 5$ e com 25 neurônios na camada oculta do ELM, similar a análise do erro médio quadrático, porém diferentemente da análise anterior, o melhor resultado foi obtido utilizando apenas 10% das amostras para o treinamento, em detrimento dos 20% utilizados no melhor resultado da análise anterior.

Em relação aos dados obtidos na Figura 5, pode-se visualizar que a variação do erro absoluto máximo possui um abrupto aumento nas séries temporais centrais a esquerda das correntes que resultam em uma maior potência óptica de saída (ver Figura 2), e em relação ao erro absoluto médio, possui uma certa uniformidade.

5 Conclusão

A alternativa de modelagem da potência óptica de saída dos lasers de pontos quânticos semicondutores utilizando uma modelagem similar ao NARX em conjunto com o ELM mostrou-se promissora, com erros

médios quadráticos relativamente baixos, apesar de certas distorções em relação aos erros absolutos e à variação do erro nas diferentes séries temporais testados, principalmente ao se considerar o custo computacional inferior à outras modelagens, como a de multipopulações.

Para futuros trabalhos, deverá ser avaliado o comportamento da modelagem NARX/ELM completa, ou seja, utilizando a saída do ELM na retroalimentação do modelo, além disso, pretende-se verificar os resultados com o laser em outras temperaturas de operação, e o desempenho de outros tipos de redes neurais, além de comparar os erros obtidos nas simulações com os erros de outras modelagens tradicionais e seus respectivos custos computacionais.

Agradecimentos

Os autores agradecem ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo apoio concedido ao desenvolvimento deste trabalho e a Stefan Breuer e Prof. Wolfgang Elsaesser (*Semiconductor Optics Group da Technical University of Darmstadt*) pelo fornecimento dos dados experimentais utilizados no artigo.

Referências Bibliográficas

- Alazrai, R. and Lee, C.S.G (2012) Na NARX-Based Approach for Human Emotion Identification, IN: IEE/RSJ International Conference on Intelligent Robots and Systems, Vilamoura, Portuga.
- Bimberg, D and Ledentsov, N.(2003) Quantum dots: lasers and amplifiers, *J. Phys.: Condens. Matter* 15 (24) (2003) R1063–R1076.
- Cao, J., Lin, Z. and Huang, G.B. (2012). Selfadaptive evolutionary extreme learning machine, *Neural Processing Letters* 36(3): 285 – 305.
- Djie, H.S., Ooi, B.S., Fang, X.M., Wu, Y., Fastenau, J.M., Liu, W.K. and Hopkinson, M. (2007) Room-temperature broadband emission of an InGaAs/GaAs quantum dots laser, *Opt. Lett.* 32 (1), 44–46.
- Drzewietzki, L. (2010) Theoretical and Experimental Investigations of the Temperature Dependent Continuous Wave Lasing Characteristics and the Switch-On Dynamics of InAs/GaAs Quantum-Dot Semiconductor Laser, *Opt. Comm.*, vol. 283, pp. 5092-5098.
- Grundmann, M., Heitz, R., Bimberg, D., Sandmann, J.H.H. and Feldmann, J. (1997) Carrier Dynamics in Quantum Dots: Modeling with Master Equations for the Transitions between Micro-States, *Physica Status Solidi B*, vol. 203, no. 1, pp. 121-132.
- Huang, G.B., Zhu, Q.Y. and ZIEW C.K. (2006) Extreme learning machine: Theory and applications. *Neurocomputing*, v. 1_3, n. 70, p. 489_501.
- Huang, G.-B., and Chen, L. (2007). Convex incremental extreme learning machine. *Neurocomputing*, 70(16), 3056–3062.
- Huang, G., Huang, Song, G., S. and You K. (2014) Trends in extreme learning machines: A review, *Neural Networks*.
- Krakowski, M., Resneau, P., Calligaro, M., Liu, H. and Hopkinson, M. (2006) High power, very low noise, c.w. operation of 1.32μm quantum-dot fabry-perot laser diodes, *IEEE 20th International Semiconductor Laser Conference, Conference Digest* 39–40.
- Ljung, L. (1999) *System Identification: Theory for the User*. 2nd. ed. Englewood Cliffs, NJ: Prentice-Hall.
- Nielsen, T., Gartner, P. and Jahnke, F. (2004) Many-body theory of carrier capture and relaxation in semiconductor quantum-dot lasers, *Phys. Rev. B* 69 (23).doi:10.1103/PhysRevB.69.235314, 2004.
- Pacifico, L.D.S. and Ludemir, T.B. (2012) Melhorando Redes Neurais do Tipo Extreme Learning Machine Atraves da Otimizacao por Enxame de Particulas com Mecanismo de Selecao, *Brazilian Conference on Intelligent Systems*.
- Rafailov, E., et al. (2005) High-power picosecond and femtosecond pulse generation from a two-section mode-locked quantum-dot laser, *Appl. Phys. Lett.* 87 (8). doi:10.1063/1.2032608.
- Rafailov, E. U., et al (2007) Mode-locked quantum-dot lasers, *Nat. Phot.* 1(7)(2007)395–401. doi:10.1038/nphoton.2007.120.
- Sugawara, M. et al. (2005) Modeling room-temperature lasing spectra of 1.3-μm selfassembled InAs/GaAs quantum-dot lasers: Homogeneous broadening of optical gain under current injection, *J. Appl. Phys.*, 97, 043523.
- Summers, D., et al. (2007) The influence of the gain carrier density characteristic on q-switching in quantumdot lasers, *IEEE J. Sel. Topics in Quantum Electron.* 13 (5, Part 1)1222–1226. doi:10.1109/JSTQE.2007.903853.
- Thé, G.A.P. (2009) How to simulate a semiconductor quantum dot laser: general description, *Rev. Bras. Ensino Fis.*, vol. 31, no. 2, doi:10.1590/S1806-11172009000200003.
- Thé, G.A.P. (2010) Improved modeling and simulation of quantum dot lasers, PhD Thesis, Politecnico di Torino, Turin.
- Thé, G. A. P. (2012) Rate-equations based model for the 2D-0D direct channel in quantum dot lasers, In: 15o SBMO Simposio Brasileiro de Microondas e Optoeletronica, Joao Pessoa.
- Viktorov, E., Mandel, P., Tanguy, Y., Houlihan, J., Huyet, G. (2005) Electron-hole asymmetry and two-state lasing in quantum dot lasers, *Appl. Phys. Lett.* 87 (5). doi:10.1063/1.1995947, 2005.
- Yang, Y. M., Wang, Y. N., and Yuan, X. F. (2012). Bidirectional extreme learning machine for regression problem and its learning effectiveness. *IEEE Transactions on Neural Networks and Learning Systems*, 23(9), 1498–1505.