

# Estudo comparativo entre algoritmos genéticos adaptativos e não-adaptativos aplicados à modelagem ambiental de *Peponapis* e *Cucurbita*

R. L. Stange, T. C. Giannini, F. S. Santana, J. J. Neto, A. M. Saraiva

**Resumo** — A modelagem ambiental pode ser feita combinando dados ambientais e de espécies para gerar modelos de distribuição, o que requer algoritmos não triviais. O objetivo deste trabalho é comparar os algoritmos GARP, um dos mais utilizados, e ADAPTGARP, que implementa um ferramental adaptativo. Os experimentos consideraram diversas espécies dos gêneros *Peponapis* e *Cucurbita*, respectivamente polinizadores e polinizados. Os resultados dos experimentos comparativos apresentaram mapas de distribuição das espécies com áreas potenciais de ocorrência muito semelhantes e variações de AUC, medida mais aceita em modelagem, dentro dos limites de tolerância. Foi possível concluir que os algoritmos são equivalentes e que o ferramental adaptativo está adequado, que é a principal contribuição deste trabalho. A partir dela, futuros trabalhos podem ser desenvolvidos em adaptatividade, envolvendo inserção de características mais gerais de algoritmos genéticos e inclusão de novos tipos de tratamentos, com o objetivo de gerar modelos mais precisos do que os atuais.

**Palavras chaves** — Sistemas adaptativos, tabelas de decisão adaptativas, algoritmos adaptativos, *Peponapis*, *Cucurbita*, modelagem ambiental.

## I. NOMENCLATURA

AUC - Área sob a Curva

GARP – Genetic Algorithm for Rule-set Production

ROC - Gráfico do Receptor-Operador

SIG – Sistema de Informação Geográfica

## II. INTRODUÇÃO

A MODELAGEM ambiental representa, atualmente, um dos maiores problemas para o desenvolvimento sustentável [3]. O mapeamento da distribuição geográfica das espécies é um dos seus maiores desafios, uma vez que as informações existentes são em geral raras, estão mundialmente distribuídas em diversas instituições de estudo, pesquisa ou

empresas relacionadas à área ambiental, e apresentam níveis de confiabilidade e qualidade bastante variáveis [17].

A modelagem de nicho ecológico é uma das técnicas atualmente mais usadas para obter a distribuição geográfica das espécies. Os modelos obtidos são representações gráficas de uma combinação de pontos de ocorrência de espécies e de dados ambientais, tais como temperatura, altitude e precipitação. O processo de modelagem é descrito em detalhes em [20].

Para a geração de um modelo são necessários métodos específicos, capazes de calcular a função de distribuição probabilística de uma espécie, que são implementados na forma de algoritmos computacionais. Dentre os diversos algoritmos disponíveis, os mais aplicados atualmente são o GARP [<http://nhm.ku.edu/desktopGARP>] ou a sua principal variação, conhecida como GARP *BestSubsets* (que efetua diversas execuções do GARP e tenta selecionar os melhores modelos), e o MAXENT (baseado em entropia máxima) [<http://www.cs.princeton.edu/~schapire/maxent>]. Todos estão também disponíveis na solução openModeller [<http://openmodeller.sourceforge.net>], que ainda integra outros algoritmos e fontes de dados.

Considerando o alto índice de utilização do GARP pelos pesquisadores em biodiversidade, foi desenvolvido um algoritmo adaptativo baseado em tabelas de decisão, denominado ADAPTGARP, inicialmente apresentado em [2]. Porém, não foi realizado um estudo detalhado a respeito dos resultados obtidos por este novo algoritmo, para determinar sua aplicação efetiva em modelagem de nicho ecológico e, com isso, dar continuidade à implementação do potencial da adaptatividade na solução deste problema.

A proposta deste trabalho é, portanto, apresentar um estudo comparativo entre os algoritmos GARP e ADAPTGARP para modelagem de nicho ecológico, usando como base para os experimentos duas espécies do gênero *Peponapis* e duas de *Cucurbita*.

O gênero *Peponapis* (Eucerini: Apidae) é constituído de abelhas solitárias com distribuição Neotropical. Esse gênero está diretamente associado às espécies de *Cucurbita*, pois coletam pólen e néctar em suas flores, e constroem os ninhos no solo, junto a essa espécie. O gênero *Cucurbita* apresenta algumas espécies que têm grande importância agrícola (abóboras) e sugere-se que a distribuição atual de *Peponapis* tenha sido influenciada pelo cultivo dessas espécies [13].

Embora atualmente ainda exista alguma controvérsia no que se refere à validação de modelos, sob a alegação de que os métodos para avaliação e comparação de algoritmos ainda não estão suficientemente bem definidos para este domínio [14],

---

The authors are grateful to FAPESP – Fundação de Amparo à Pesquisa do Estado de São Paulo – Brazil, for the support to the openModeller (04/11012-0) and BioAbelha (04/15801-0) projects.

R. L. Stange is a Master Student at Escola Politécnica da Universidade de São Paulo, Computation and Digital Systems Department, Av. Prof. Luciano Gualberto, travessa 3, número 158 - Cidade Universitária - São Paulo - SP - CEP: 05508-900 (rlstange@gmail.com).

T. C. Giannini is a PhD Student at Bioscience Institute, Department of Ecology, Rua do Matão, trav. 14, n 321 - Cidade Universitária - São Paulo - SP - CEP: 05508-900 (giannini@usp.br).

F. S. Santana is a PhD Student at Escola Politécnica da Universidade de São Paulo, Computation and Digital Systems Department, Av. Prof. Luciano Gualberto, travessa 3, número 158 - Cidade Universitária - São Paulo - SP - CEP: 05508-900 (fabiana.santana@usp.br).

J. J. Neto and A. M. Saraiva are both professors at Escola Politécnica da Universidade de São Paulo, Computation and Digital Systems Department, Av. Prof. Luciano Gualberto, travessa 3, número 158 - Cidade Universitária - São Paulo - SP - CEP: 05508-900 (joao.jose@poli.usp.br, amsaraiv@usp.br).

neste estudo optou-se por utilizar a metodologia proposta em [1]. Esta é, a despeito de todas as críticas, a mais bem aceita entre os especialistas da comunidade de pesquisa em biodiversidade. Como os objetivos principais são comparar os resultados obtidos pelo ADAPTARP e pelo GARP em relação aos seus aspectos algorítmicos e analisar a eficácia do ferramental adaptativo implementado, este trabalho não se aprofunda nos aspectos ecológicos das espécies enfocadas.

### III. MATERIAIS E MÉTODOS

#### A. Abordagem geral sobre tecnologias adaptativas

O termo adaptatividade pode ser definido como a capacidade que um sistema tem para modificar o seu comportamento de forma espontânea, em resposta apenas ao seu histórico de operação e aos dados de entrada, sem interferência de agentes externos [16].

O foco principal do estudo da tecnologia adaptativa é a resolução de problemas práticos através da aplicação de modelos baseados em dispositivos adaptativos. O formalismo geral que caracteriza os dispositivos adaptativos foi apresentado pela primeira vez em [15].

Nestes dispositivos, um conjunto finito de regras pode ser representado através de uma coleção de condições que testam a situação atual do dispositivo e, quando aplicável, levam o dispositivo para uma próxima situação. Quando uma única regra é aderente à situação atual do dispositivo, a próxima situação é determinada pela regra em questão. Em situações em que mais de uma regra adere ao estado corrente do dispositivo, as possíveis situações são tratadas em paralelo e o dispositivo deve exibir uma operação não-determinística. No caso de nenhuma regra ser aderente à situação corrente, a operação do dispositivo pode ser descontinuada. Os formalismos subjacentes dos dispositivos adaptativos podem ser classificados de acordo com diversas categorias, conforme sua forma de operação. Os principais são [16]:

- Dispositivos de reconhecimento: pertencem à classe dos autômatos e são baseados na sucessão de mudanças de estados;
- Dispositivos de geração de classes das gramáticas: são baseados na aplicação sucessiva de regras de substituição;
- Dispositivos para a representação de sistemas assíncronos: incorporam mecanismos responsáveis pela representação de fenômenos de sincronização;
- Dispositivos estocásticos: incluem dispositivos semelhantes às cadeias de Markov e são capazes de representar fenômenos de caráter aleatório;
- Dispositivos de processamento: incluem dispositivos tais como as linguagens de programação adaptativas, que permitem descrever a lógica de programas com código automodificável;
- Dispositivos de auxílio à tomada de decisões: são representados principalmente pelas tabelas de decisão e pelas árvores de decisão.

A opção para o desenvolvimento deste trabalho foi o uso de tabelas de decisão adaptativas, incluídas no último item da classificação apresentada acima.

#### B. Tabelas de decisão adaptativas

Uma tabela de decisão convencional [18] é composta por colunas que representam conjuntos de regras associadas a condições e ações. A primeira coluna, partindo da primeira linha da tabela, representa um conjunto de condições e, a seguir, encontra-se um conjunto de ações. A tabela de decisão opera verificando as condições de acordo com os valores definidos nas colunas de regras. Quando a condição é satisfeita de acordo com uma determinada regra, essa regra é considerada válida e todas as ações a ela associadas são executadas. Uma tabela de decisão convencional é mostrada na Tabela 1.

TABELA 1  
TABELA DE DECISÃO CONVENCIONAL [2]

		0	1	2	3	4	5	6	7	8	9
Condições	c <sub>1</sub>										
	c <sub>2</sub>										
	...										
	c <sub>n</sub>										
Ações	a <sub>1</sub>										
	a <sub>2</sub>										
	...										
	a <sub>m</sub>										

Uma versão adaptativa de uma tabela de decisão convencional pode ser obtida adicionando-se um número de linhas a ela onde são incluídas as funções adaptativas. Além disso, a cada coluna que representa uma regra simples, deve ser adicionada uma chamada para uma função adaptativa associada à execução de uma regra em particular. Com isso, sempre que uma regra é aplicada, uma função adaptativa é invocada, permitindo mudanças no conjunto de regras.

A *Tabela de Decisão Adaptativa* é definida como um dispositivo guiado por regras, onde ações adaptativas permitem mudanças no conjunto de regras da tabela de forma dinâmica [2]. A possibilidade de mudanças no conjunto de regras é, essencialmente, o que caracteriza a adaptatividade do dispositivo. A estrutura geral de uma tabela de decisão adaptativa é apresentada na Tabela 2, baseada no formato descrito em [15] e na tabela de decisão convencional descrita em [9]. Observe o acréscimo de linhas e colunas para as funções e ações adaptativas.

Na execução de uma condição em uma Tabela de Decisão Adaptativa, primeiramente são verificadas as regras não-adaptativas e, se uma única delas se aplica, as ações correspondentes são executadas. Caso mais de uma regra não-adaptativa satisfaça a condição, as ações correspondentes às mesmas devem ser aplicadas em paralelo, como previamente definido para tabelas de decisão convencionais.

Porém, se nenhuma regra satisfizer a condição, trata-se de uma condição não prevista e, no caso de uma tabela de decisão convencional, não haveria como prosseguir. Porém, na solução adaptativa deve-se verificar, nesse caso, se uma regra adaptativa se aplica, para que ações adaptativas sejam executadas e o conjunto de regras não-adaptativas seja alterado. Isto faz com que o comportamento do sistema se modifique e, uma vez aplicada à regra, utiliza-se novamente a tabela de decisão adaptativa em sua configuração resultante.

TABELA 2  
TABELA DE DECISÃO ADAPTATIVA [2]

							D <sub>1</sub>	D <sub>2</sub>	...	D <sub>h</sub>	R <sub>1</sub>	R <sub>2</sub>	...	R <sub>h</sub>
		0	1	2	3	4	5	6	7	h + 4				
Condições	c <sub>i</sub>													
	...													
	c <sub>n</sub>													
Ações	a <sub>i</sub>													
	...													
	z <sub>m</sub>													
Funções Adaptativas	b <sub>a<sub>i</sub></sub>													
	...													
	b <sub>a<sub>f</sub></sub>													

### C. O problema de modelagem de nicho ecológico

O problema da modelagem de nicho ecológico está relacionado às condições que permitem à sobrevivência de uma determinada espécie, o que tipicamente conhecido como nicho, tais como temperatura, geologia e vegetação, sendo desconsiderados os fatores externos, como a influência do homem, as interações bióticas e as barreiras geográficas [16].

O conceito de nicho ecológico é definido em [16] como o conjunto de condições ecológicas e ambientais sob as quais uma espécie é capaz de manter suas populações sem a necessidade de imigração e, em [8], como sendo um conjunto de condições ecológicas com as quais as populações conseguem se manter sem interferência, que pode ser representado por um espaço ecológico/ambiental multidimensional, onde as condições são as dimensões deste espaço.

Portanto, baseados no conceito de nicho ecológico, a geração de modelos de distribuição geográfica de espécies precisa combinar os dados disponíveis correspondentes aos pontos de ocorrência ou ausência das espécies com os dados ambientais pertinentes ao seu nicho.

Os pontos de ocorrência correspondem aos locais em que as espécies foram encontradas. Os pontos de ausência são menos confiáveis, mas em princípio representam os pontos estudados em que a espécie foi procurada e não foi encontrada (a confiança do ponto está diretamente relacionada à metodologia de busca). Os dados ambientais são apresentados na forma de camadas, normalmente chamadas de *layers*. Todos devem ser disponibilizados na forma de coordenadas geo-referenciadas, considerando a região específica de estudo.

Um de nicho ecológico modelo é uma função de distribuição da probabilidade de ocorrência de uma espécie em cada coordenada geográfica da região de estudo e, usualmente, é projetado em um mapa geográfico em escala de cores, onde cada cor representa uma probabilidade específica. O processo de modelagem é detalhado em [19], mas é importante destacar o papel dos algoritmos nesse processo, pois são eles os responsáveis por obter, a partir de dados usualmente escassos, o mapeamento da distribuição das espécies.

### D. O algoritmo GARP

O GARP é um algoritmo genético, neste contexto adaptado para o propósito de realizar modelagem de nicho ecológico. O

termo algoritmo genético foi introduzido por [7] para explicar os mecanismos da evolução natural e para transformar estes mecanismos em sistemas artificiais, com o objetivo de resolver problemas difíceis de busca e otimização.

Esse algoritmo utiliza conceitos de nicho ecológico para definir uma população e, a partir disso, trabalha no processamento das regras que definem esse nicho. O algoritmo procura encontrar o nicho de uma espécie analisando diversos *layers* ambientais. As regras a que o GARP se refere estão diretamente relacionadas a estes *layers*.

A implementação do GARP considera três tipos de regras: *ranges rules*, *negate rules* e *logit rules*. *Range rules* podem ser escritas, em linguagem natural, como “Se o valor da variável ambiental X está entre os valores A e B, onde A é menor que B, então a espécie está presente”. *Negative rules* capturam os pontos de presença das espécies para valores de uma variável ambiental a partir de um determinado intervalo: “Se o valor da variável ambiental X é menor que o valor de A ou o valor da variável X é maior o valor de B, onde A é menor que B, então a espécie está presente”. *Logit rules* refletem os pontos de ocorrência das espécies como uma função de distribuição de probabilidade em termos de diferentes variáveis ambientais: “Considerando que as variáveis  $x_1, x_2, \dots, x_n$  determinam os pontos de presença de espécies em uma determinada área geográfica, a probabilidade de ocorrência de espécies em um ponto específico  $p_0$  desta área é dado por:  $\text{Prob}(a \text{ espécie está presente em } p_0) = 1 - e^{-x_1 + x_2 + \dots + x_n}$ ”.

A Figura 1 apresenta o GARP em pseudo-código, de acordo com a implementação atual disponível no sistema openModeller (<http://openmodeller.sourceforge.net>), que é de fato a mais utilizada. A implementação considera a criação de um conjunto de regras, chamado de *\_offspring*, que também armazena o conjunto de regras resultante de cada iteração do algoritmo. A quantidade de regras é limitada por *\_popsize*, que é um parâmetro constante pré-definido e que armazena o tamanho da população. A operação de colonização consiste em gerar regras para *\_offspring*, sendo que inicialmente este conjunto de regras deve ser preenchido com exatamente *\_popsize* regras. O método *initializeGARP* é executado apenas uma vez, para gerar o conjunto inicial de regras. Depois disso, o método *iterateGARP* é chamado, onde a cada iteração, o tamanho do conjunto de regras é controlado, a fim de que o tamanho estabelecido em *\_popsize* seja mantido. Caso a quantidade de regras em *\_offspring* seja menor do que *\_popsize*, a operação de colonização é chamada para criar novas regras; caso contrário, algumas regras devem ser removidas de *\_offspring*, sendo que a remoção deve sempre tentar manter o maior valor possível para a função de adaptação do conjunto de regras, conhecida como função de *fitness*. O método *keepFittest* realiza a substituição de uma regra no conjunto de regras se ela fornecer uma performance melhor do que a regra similar, ou insere uma regra que seja capaz de melhorar a função de *fitness* do conjunto de regras, se nenhuma regra similar for encontrada. Esta operação garante que o valor da função de *fitness*, na pior das hipóteses, se mantém. Na sequência, os métodos tradicionais dos algoritmos genéticos são executados, que são: *Select*, *Crossover* e *Mutate*.

Após estas operações, o desempenho de cada regra no conjunto de regras é individualmente avaliado e, em seguida, um filtro remove as regras que resultam em redução do valor da função de *fitness*. Por último, o número de iterações é acrescido de um, a fim de estabelecer um limite máximo para o número de iterações. Portanto, o método *iterateGARP* é repetido até que ocorra a convergência (os valores de convergência são parâmetros fixos e pré-definidos) ou até que o número máximo de iterações seja atingido. Portanto, o número de iterações executadas de fato depende dos dois critérios, sendo que o algoritmo para sua execução no que for satisfeito primeiro.

### E. O algoritmo ADAPT GARP

O ADAPT GARP é uma versão adaptativa do GARP proposta em [2], considerando a versão implementada no openModeller [http://openmodeller.sourceforge.net] e baseado no uso de Tabelas de Decisão Adaptativas.

Os operadores *Crossover* e *Mutation* (na implementação, este operador aparece com o nome de *Mutate*) trabalham como manipuladores de regras através de outras regras e são chamados pelo algoritmo principal. A adaptatividade consiste na inclusão dos respectivos operadores genéticos adaptativos, chamados de *AdaptCrossover* e *AdaptMutation*, que são capazes de alterar as regras a serem manipuladas pelos operadores *Crossover* e *Mutation*. A estrutura de dados é descrita de acordo com as técnicas adaptativas presentes em [15].

O operador genético *Crossover* escolhe dois indivíduos e troca informações entre eles, produzindo um novo indivíduo. No caso do GARP, isto se aplica aos limites dos dados referentes ao nicho da espécie em estudo, atuando sobre os seus limites. A técnica requer que regras de dispositivos não-adaptativos sejam codificadas em tabelas de decisão. Portanto, é necessário definir funções adaptativas para manipulação das regras inseridas na tabela de decisão. Essas funções adaptativas são inseridas como parte da tabela de decisão adaptativa, o que resulta em uma representação dos operadores genéticos como parte da tabela de decisão adaptativa e essas funções permitem a mudança dinâmica no conjunto de regras.

A implementação das regras do GARP foi baseada em [15]. Por exemplo, considere  $h$  o intervalo associado às variáveis ambientais  $k$ , como mostra a Tabela 3 a seguir.

TABELA 3  
ESQUEMA DE REGRAS DO GARP

	$R_1$	$R_2$	$R_3$	...	$R_h$
$x_1 \geq$	$A_{11}$	$A_{21}$	$A_{31}$	...	$A_{h1}$
$x_1 \leq$	$B_{11}$	$B_{21}$	$B_{31}$	...	$B_{h1}$
...	...	...	...	...	...
$x_k \geq$	$A_{1k}$	$A_{2k}$	$A_{3k}$	...	$A_{hk}$
$x_k \leq$	$B_{1k}$	$B_{2k}$	$B_{3k}$	...	$B_{hk}$

No GARP, um exemplo de tipo de regra associado a esta tabela poderia ser: “Se  $x_1 \in [A_{11}, B_{11}]$  e  $x_2 \in [A_{12}, B_{12}]$  e...  $x_k \in [A_{1k}, B_{1k}]$  então a espécie está presente.”

A regra  $R_j$  significa que,  $1 \leq j \leq h$ , para cada variável ambiental  $x_i$ , onde  $1 \leq i \leq k$ , então a espécie está presente na localização associada. Esta é a principal representação da

#### Método: initializeGARP

1. Cria e coloniza o conjunto de regras *\_offspring* (para armazenar o conjunto de regras resultado de cada iteração)
  - A quantidade de regras é limitada por *\_popsize* (tamanho da população)
  - A colonização consiste em gerar regras

#### Método: iterateGARP

1. Controla o tamanho da população
  - Coloniza o conjunto de regras se o tamanho de *\_offspring* < *\_popsize*
  - Remove regras se o tamanho de *\_offspring* > *\_popsize*
2. Executa o método *keepFittest*
  - Substitui uma regra no conjunto de regras se ela fornecer uma performance melhor do que a regra similar
  - Insere uma regra no conjunto de regras se não for encontrada uma regra similar
  - Isso mantém ou melhora a performance do conjunto de regras
3. Realiza os métodos tradicionais dos algoritmos genéticos
  - Select: avalia a *fitness* dos membros e seleciona indivíduos capazes de se reproduzir
  - Crossover: Troca partes de dois indivíduos pais e constrói uma nova *\_offspring*
  - Mutate: Troca aleatoriamente partes de *\_offspring*
4. Avalia a performance de cada regra no conjunto de regras
5. Filtra regras
  - Remove regras com baixo valor de *fitness*
6. Aumenta o número de iterações

Figura 1 – Algoritmo GARP, implementação openModeller.

estrutura de dados para operadores genéticos adaptativos descritos a seguir. O número de colunas da Tabela 4 podem mudar com a execução do operador *AdaptCrossover*. Já o *AdaptMutation* atua em regras já existentes na tabela de decisão, alterando os limites dos intervalos.

Algumas decisões devem ser tomadas sobre como lidar com as regras. Qualquer regra é referida pelo índice da tabela, por exemplo, sua respectiva coluna. Dado que se trata de um dispositivo adaptativo, o número de regras pode ser alterado e o conjunto de regras a ser considerado deve ser uma estrutura matricial dinâmica, que mantém a numeração sequencial das colunas.

Para especificar as funções adaptativas, funções auxiliares são aplicadas, que são descritas a seguir:

- a)  $Ux(y) = \begin{cases} 0, & \text{if } x < y \\ 1, & \text{if } x \geq y \end{cases}$
- b) A função *rand(n)* gera um número inteiro aleatório entre 1 e  $n$ , e a função *rand(a,b)*, produz um número inteiro aleatório entre  $a$  e  $b$ , quando  $a$  e  $b$  inteiros, ou um número real aleatório entre  $a$  e  $b$ , quando  $a$  e  $b$  são números reais (isto depende da definição dos dados analisados sobre a espécie ou *layer*).

Na implementação do *AdaptCrossover*, considera-se que o operador genético *Crossover* escolhe dois indivíduos e troca informações genéticas entre eles, produzindo um novo indivíduo. A Tabela 4 especifica a função adaptativa do operador *AdaptCrossover* na tabela de decisão.

A célula da primeira linha na primeira coluna é usada para identificar o nome da função. As outras células desta linha ficam vazias. A segunda coluna, entre a segunda e a quinta linha, são utilizadas para especificar os parâmetros do operador *AdaptCrossover*. Os parâmetros  $i$  e  $j$  são números inteiros, representando os índices das regras a serem cruzadas. Os parâmetros  $p$  e  $q$  são números inteiros que especificam seções de intervalos que são herdadas pelo novo indivíduo, resultantes do cruzamento entre as regras  $i$  e  $j$ . As linhas

restantes especificam as condições adaptativas, de acordo com as funções adaptativas.

A função adaptativa pode adicionar uma nova linha na tabela, que é expressa pelo símbolo “+” no cabeçalho da terceira coluna. Outra ação elementar é o símbolo “-”, que remove regras. Este símbolo também é aplicado na versão adaptativa do operador de mutação, mostrado na tabela 5. O operador *AdaptCrossover* cria novas regras para que todos os intervalos com índice “< p” ou “≥ q” herdem a regra  $R_i$ .

TABELA 4  
TABELA DE DECISÃO ADAPTATIVA PARA ADAPTCROSSOVER

		+
	<b>AdaptCrossover</b>	
	<i>I</i>	
	<i>J</i>	
	<i>P</i>	
	<i>Q</i>	
$x_i \geq$		$A_{i1} + (A_{j1} - A_{i1})(U_i(p) - U_i(q))$
$x_i \leq$		$B_{i1} + (B_{j1} - B_{i1})(U_i(p) - U_i(q))$
...		...
$x_k \geq$		$A_{ik} + (A_{jk} - A_{ik})(U_k(p) - U_k(q))$
$x_k \leq$		$B_{ik} + (B_{jk} - B_{ik})(U_k(p) - U_k(q))$

As regras do *AdaptCrossover* podem ser matematicamente resumidas por:

$$x_h \geq \begin{cases} A_{ih}, & \text{if } h < p \\ A_{jh}, & \text{if } p \leq h < q \\ A_{ih}, & \text{if } h \geq q \end{cases}$$

e

$$x_h \leq \begin{cases} B_{ih}, & \text{if } h < p \\ B_{jh}, & \text{if } p \leq h < q \\ B_{ih}, & \text{if } h \geq q \end{cases}$$

para todo  $1 \leq h \leq k$ .

O operador genético de mutação, o *Mutation*, seleciona um indivíduo e pode modificar as informações a ele pertinentes, produzindo a mutação do indivíduo, no caso das regras do GARP. A Tabela 5 apresenta a função adaptativa *AdaptMutation* como uma tabela de decisão [2]. A célula da primeira linha e primeira coluna é usada somente para identificar o nome da função. Na segunda coluna, as linhas entre dois e cinco especificam os parâmetros do *AdaptMutation*. O parâmetro *j* é um número inteiro que representa o índice associado a uma regra; os valores de *k* e *g* são números inteiros aleatórios; *k* especifica um gene a ser modificado; *g* especifica se o *k*-ésimo gene será modificado ou não; e os parâmetros *a* e *b* são números inteiros aleatórios que representam os novos limites para o intervalo, se ele for alterado.

TABELA 5  
TABELA DE DECISÃO ADAPTATIVA PARA ADAPTMUTATION

		-	+
	<b>AdaptMutation</b>		
	<i>j</i>		
	<i>r</i>		
	<i>g</i>		
	<i>a</i>		

	<i>b</i>		
$x_i \geq$		$A_{ji}$	$A_{ji}U_i(g) - (a - A_{ji})U_i(g + 1)$
$x_i \leq$		$B_{ji}$	$B_{ji}U_i(g) - (b - B_{ji})U_i(g + 1)$
...			
$x_k \geq$		$A_{jk}$	$A_{jk}U_i(g) - (a - A_{jk})U_i(g + 1)$
$x_k \leq$		$B_{jk}$	$B_{jk}U_i(g) - (b - B_{jk})U_i(g + 1)$

As regras do *AdaptMutation* podem ser matematicamente resumidas por:

$$x_h \geq \begin{cases} A_{jh}, & \text{if } r < g \\ a, & \text{if } r = g \\ A_{jh}, & \text{if } r > g \end{cases}$$

e

$$x_j \leq \begin{cases} B_{jh}, & \text{if } r < g \\ b, & \text{if } r = g \\ B_{jh}, & \text{if } r > g \end{cases}$$

para todo  $1 \leq h \leq k$ .

#### IV. ESTUDO COMPARATIVO ENTRE O GARP E O ADAPT GARP

Esta seção apresenta os resultados do estudo comparativo entre os algoritmos GARP e ADAPT GARP dentro do contexto do problema de modelagem de nicho ecológico, a fim de validar o ferramental adaptativo proposto pelo uso das Tabelas de Decisão Adaptativas.

Para comparar os dois algoritmos, foram utilizados os pontos de ocorrência de duas espécies de *Peponapis* e duas de *Cucurbita*, obtidas a partir de sítios na Internet que apresentam dados de herbários e coleções. São eles: rede *speciesLink* [<http://splink.cria.org.br/>], CONABIO (Comisión Nacional para el Conocimiento y uso de la Biodiversidad – [<http://www.conabio.gob.mx/>]) e GBIF (Global Biodiversity Information Facility [<http://www.gbif.org/>]). Foram também consideradas as informações apresentadas em [10][11][12], onde essas espécies foram extensamente estudadas, do ponto de vista biológico. A Tabela 6 resume os dados utilizados no experimento.

TABELA 6  
ESPÉCIES E NÚMERO DE PONTOS DE OCORRÊNCIA ANALISADOS

Nome Científico	N. de pontos de ocorrência	Países que apresentam registro da espécie
<i>P. timberlakei</i> Hurd & Linsley, 1964	31	EUA e México
<i>P. azteca</i> Hurd & Linsley, 1966	60	México
<i>C. palmata</i> S. Watson	90	EUA e México
<i>C. radicans</i> Naudin	39	México

As coordenadas geográficas, organizadas por municípios, foram obtidas a partir de dois principais sítios da Internet. Para o Brasil, foi utilizada uma ferramenta oferecida pela própria rede *speciesLink*, denominada *geoloc*, e para os demais países utilizou-se o sítio da Internet denominado Taseo [<http://www.taseo.com>]. A conversão para graus decimais, a limpeza e a correção dos dados foram feitas também através das ferramentas presentes no sítio do *speciesLink* e denominadas, respectivamente, de *conversor*, *datacleaning* e *speciesmapper*.

A modelagem de nicho ecológico das quatro espécies foi feita utilizando os algoritmos GARP e ADAPT GARP. Porém,

como a análise aqui proposta sempre teve o objetivo e o compromisso de estar o mais próxima possível da realidade, e a maior parte da comunidade de pesquisa em biodiversidade utiliza a versão do GARP conhecida como “GARP with best subsets”, o ADAPTGARP também foi implementado seguindo os mesmos padrões. Portanto, ao invés de utilizar diretamente o algoritmo proposto em [2], foi implementada uma versão do ADAPTGARP usando os mesmos conceitos de “best subsets”, resultando na implementação do “ADAPTGARP with best subsets”.

Na modelagem feita pelo GARP, os pontos de ocorrência são divididos em dois conjuntos de dados para cada iteração do algoritmo, sendo que um deles é utilizado para testar a qualidade do modelo gerado (dados para teste) e o outro é usado para desenvolver efetivamente o modelo (dados para treino). O modelo é composto por regras que são desenvolvidas através de refinamento, teste e seleção de subconjuntos dos dados de teste. O desempenho do modelo foi medido através do método conhecido como “área sob a curva” (AUC - *area under curve*) do gráfico do receptor-operador (ROC - *receiver operating characteristic*), que é calculada a partir dos valores da matriz de confusão [4]. Como discutido anteriormente, embora não haja consenso sobre os métodos de validação de modelos, este método é o mais adotado pela comunidade de pesquisa em biodiversidade atualmente e, portanto, foi considerado como a melhor alternativa de comparação também para este estudo.

Foram feitos dois tipos de testes: um deles, denominado *teste interno*, usa a totalidade dos pontos de ocorrência obtidos e o outro, denominado *teste externo* (ou *teste independente*), que efetua divisões dos dados em partições, de forma aleatória e sem reposição, sendo que cada partição, por sua vez, será dividida em dados de teste e dados de treino (Tabela 7) no momento da execução dos algoritmos. Este teste é bastante importante, pois associa uma espécie de análise de sensibilidade nos modelos gerados, em relação aos dados de entrada.

TABELA 7  
NÚMERO DE PARTIÇÕES DE CADA ESPÉCIE PARA O TESTE EXTERNO UTILIZANDO-SE DADOS DE TESTE (30%) E DADOS DE TREINO (70%).

Nome científico	N. de partições	N. de pontos para teste (30%)	N. de pontos para treino (70%)
<i>C. palmata</i>	3	9	21
<i>P. azteca</i>	2	9	21
<i>P. timberlakei</i>	1	9	21
<i>C. radicans</i>	1	9	21

Foi usado o limite proposto por [22], que estipula que os dados de treino devem conter no mínimo 20 pontos de ocorrência. A proporção adotada entre número de pontos de treino e número de pontos de teste foi de 70% e 30%, respectivamente.

Foram calculadas a média e o desvio padrão dos valores de AUC obtidos para cada partição de dados de cada espécie. [1] sugere que os resultados do AUC médio sejam interpretados da seguinte forma: excelente, quando acima de 0,90; bom, entre 0,90-0,80; razoável, entre 0,80-0,70; pobre, entre 0,70-

0,60; e falho, entre 0,60-0,50.

Foi utilizada uma máscara com grade de 9km<sup>2</sup> de resolução, abrangendo o continente americano (aproximadamente 765 mil células) e 37 camadas ambientais, com mesma resolução, obtidas no sítio do Worldclim [http://www.worldclim.org]. As camadas utilizadas na modelagem referem-se à: 1) Altitude; 2) Precipitação para 12 meses; 3) Temperatura máxima para 12 meses; e 4) Temperatura mínima para 12 meses.

Para as análises das informações geográficas obtidas foi utilizado o programa ArcGIS, versão 9.2 [http://www.esri.com/software/arcgis/index.html], que também é uma das ferramentas de SIG mais adotadas pela comunidade de pesquisa em biodiversidade.

## V. RESULTADOS

A Figura 2 mostra os mapas resultantes da modelagem de cada espécie a partir de cada algoritmo.

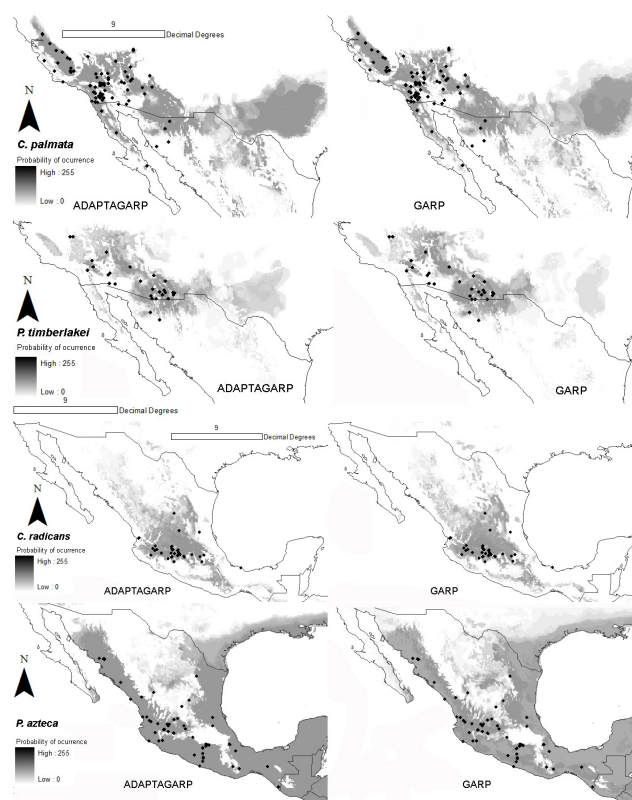


Figura 2 – Mapas de distribuição evidenciando as áreas potenciais da espécie *Cucurbita palmata*, *Peponapis timberlakei*, *C. radicans* e *P. azteca*, obtidos através da modelagem utilizando-se GARP e ADAPTGARP “with best subsets”.

A Tabela 8 apresenta os resultados de AUC obtidos a partir do teste interno executado com a totalidade de pontos de ocorrência para cada espécie e a Figura 3 mostra o gráfico comparativo entre estes valores.

TABELA 8  
RESULTADOS DE AUC DO TESTE INTERNO

Nome Científico	GARP AUC	ADAPTGARP AUC
<i>C. palmata</i>	0.90	0.90
<i>P. timberlakei</i>	0.86	0.89

<i>C. radicans</i>	0.97	0.97
<i>P. azteca</i>	0.97	0.96

A tabela 9 apresenta as médias e desvios padrão dos AUC obtidos através do teste externo, realizado com as partições dos dados para a execução do GARP e do ADAPTGARP “with best subsets”. Da mesma forma, a Figura 4 apresenta o resumo gráfico dos resultados obtidos.




Figura 3 - Valores obtidos para o AUC no teste interno

TABELA 9  
RESULTADOS DE AUC DO TESTE EXTERNO

Nome Científico	GARP			
	Teste (30%)		Treino (70%)	
	Média	DP	Média	DP
<i>C. palmata</i>	0.87	0.12	0.96	0.03
<i>P. timberlakei</i>	0.89	-	0.94	-
<i>C. radicans</i>	0.93	-	0.95	-
<i>P. azteca</i>	0.95	0.01	0.96	0.04
	ADAPTGARP			
	Média	DP	Média	DP
	Média	DP	Média	DP
<i>C. palmata</i>	0.83	0.09	0.91	0.02
<i>P. timberlakei</i>	0.89	-	0.90	-
<i>C. radicans</i>	1.00	-	0.95	-
<i>P. azteca</i>	0.97	0.05	0.96	0.05




Figura 4 – Valores obtidos para o AUC no teste externo

## VI. ANÁLISE DOS RESULTADOS, INOVAÇÕES E DISCUSSÕES SOBRE TRABALHOS FUTUROS

Observe que, mesmo visualmente, é possível notar a

semelhança entre os modelos gerados, através da observação dos mapas obtidos para cada espécie, utilizando-se os dois algoritmos, conforme apresentado na Figura 2. Observe que as áreas potenciais de ocorrência são de fato muito semelhantes. Da mesma forma, os resultados de AUC do teste interno apresentados na Tabela 8 mostram valores semelhantes para os dois algoritmos.

No entanto, as duas espécies de *Peponapis* apresentaram resultados diferentes para o teste interno (Tabela 8): o ADAPTGARP resultou um modelo com valor mais alto de AUC para *P. timberlakei* e com um valor mais baixo para *P. azteca*. Em relação ao teste externo, Tabela 9, é possível observar a variação dos resultados de AUC para os dois algoritmos, especialmente nas espécies *C. palmata* e *P. timberlakei*. Apenas para essas duas espécies, os valores estiveram abaixo de 0.90. Porém, uma flutuação como esta já era esperada, devido às diferentes amostras selecionadas aleatoriamente e que, portanto, podem variar de uma execução para outra. De qualquer forma, essas diferenças não representam uma variação estatisticamente significativa para algoritmos genéticos.

É importante notar, para uma correta análise dos resultados, que a implementação atual do ADAPTGARP provê um ferramental adaptativo baseado em tabelas de decisão adaptativas e normalização de resultados. Considerando que o ADAPTGARP utiliza mecanismos adaptativos apenas para implementar a simulação do algoritmo genético, através de uma tabela de decisão adaptativa, é de se esperar que macroscopicamente os resultados apresentados sejam similares. Mais especificamente, nesta implementação, os eventuais desvios apresentados pelo GARP nas operações de *Crossover* e *Mutation* são normalizados nas respectivas implementações do *AdaptCrossover* e *AdaptMutation* do ADAPTGARP. Embora não se possa afirmar sem um estudo mais aprofundado, esta normalização provavelmente é a justificativa para a melhoria dos resultados medidos do AUC, nos casos em que isso ocorreu, embora os valores obtidos ainda continuem bastante próximos.

Embora possa se argumentar que estes resultados ainda tenham que ser submetidos à avaliação da comunidade de pesquisa em geral, através da livre disponibilização do algoritmo para experimentos com diferentes espécies com características e áreas de ocorrência também diversas, o ponto principal deste estudo é que os resultados comprovam que esta abordagem é uma opção válida para a modelagem de nicho ecológico, como era o objetivo inicial. Portanto, uma vez implementado o ferramental adaptativo, este pode e deve continuar a ser explorado e evoluído, o que deve ser feito através da inserção de “conhecimento” ao ADAPTGARP.

Além da própria implementação do “ADAPTGARP with best subsets”, que vai incentivar seu uso pela comunidade de pesquisa em biodiversidade, este trabalho foi fundamental no sentido de estabelecer uma validação mais precisa da simulação deste algoritmo genético usando tabelas de decisão adaptativas.

Com relação ao desempenho, como já havia sido avaliado em [2], constatou-se mais uma vez que os algoritmos se



comportam de maneira similar. Este fato também era previsto, pela própria estrutura do algoritmo que realiza uma simulação do GARP usando Tabelas de Decisão Adaptativas. Isto também acontece nos resultados de geração de mapas e valores de AUC. As variações observadas nos resultados, também neste caso, ocorrem devido à flutuação estatística e são perfeitamente aceitáveis.

A comprovação de que o algoritmo implementado, utilizando Tabelas de Decisão Adaptativas como dispositivo adaptativo, efetivamente simula o algoritmo genético original permite evoluções significativas no algoritmo, em termos computacionais. Portanto, o ferramental adotado pode ser considerado válido e pronto para ser trabalhado.

Uma delas é que, na implementação do próprio GARP, por sua estrutura, algumas características importantes dos algoritmos genéticos não estão devidamente cobertas, como considerar populações e probabilidades relacionadas aos seus operadores (além de crossover e mutação, por exemplo, podemos citar o caso da mortalidade). Essas características podem ser consideradas na tabela de decisão definindo-se novas condições a serem testadas, novas condições a serem incluídas e novas ações adaptativas a serem convenientemente executadas, de tal modo que os novos elementos passem a ser considerados na tomada de decisão por ela representada.

Outra contribuição é a inclusão de um mecanismo de implementação de máscaras para que determinados dados se tornem visíveis ou invisíveis aos algoritmos, conforme a conveniência. Por exemplo, isso pode ser aplicado para a seleção automática de layers ambientais, possibilitando incluir na tabela de decisão adaptativa ações para filtrar layers relevantes para cada determinado experimento. Essa técnica pode ser aplicada para considerar fatos que sejam do conhecimento do pesquisador, alterando as tabelas com o objetivo de reduzir a quantidade de dados a serem levados em conta para as tomadas de decisão. Ilustra essa situação o conhecimento prévio de valores mínimos e máximos de variáveis ambientais (altitude, temperatura, precipitação), que estão fortemente correlacionadas com ausência ou presença de determinadas espécies. Por exemplo, uma espécie que seja bem conhecida e que só ocorra em regiões desérticas, apresentará restrições relativas ao clima (nesse caso, seco), índice pluviométrico (baixo) e temperatura (baixa). O que neste exemplo foi classificado como “seco” ou “baixo(a)” pode, através do conhecimento do pesquisador (no caso, biólogo, ecólogo ou especialista de áreas afins) sobre a espécie, ser transformado em valores numéricos de mínimos e máximos, restringindo os extremos da tabela de decisão adaptativa para valores expressos em números reais.

Portanto, é possível evoluir a solução e inserir o conhecimento do pesquisador sobre a espécie que está em estudo para a construção das funções adaptativas. Portanto, ao invés de se normalizar os resultados para evitar grandes desvios, a tabela de decisão adaptativa pode utilizar valores reais baseados em fatos reais para limitar o intervalo. Se a necessidade de normalização surgir, ela ainda pode ser aplicada, mas a tendência é minimizar ainda mais o erro, por estar agora associada a valores baseados em conhecimento

pré-estabelecido.

Outra inovação é acrescentar ao ferramental adaptativo fatores de correlação, para o caso de estudos de espécies co-dependentes. Por exemplo, no caso de espécies que dependem de certos polinizadores específicos, é necessário considerar o estudo da distribuição do polinizador na distribuição da espécie vegetal enfocada. Analogamente, o estudo da distribuição do polinizador deve considerar a distribuição da espécie vegetal, pois esta é essencial como fonte de recursos para sua sobrevivência.

Além destes aspectos, diversos itens relacionados à seleção de layers, algoritmos e parâmetros também podem ser acrescentados ao ADAPTGARP, de forma que o modelo fique sempre o mais próximo possível daquilo que já é conhecido sobre a distribuição geográfica da espécie, aproximando ao máximo o modelo da realidade, que é o objetivo principal da modelagem de nicho ecológico. Com relação à seleção automática de layers, por exemplo, é possível automatizar a inclusão de novas regras e ações adaptativas que permitam ao algoritmo deduzir quais layers são essenciais e quais podem ser ignoradas em cada experimento, baseado na dedução das correlações existentes entre grupos de layers.

Cada uma dessas contribuições, brevemente descritas nesta seção, serão alvos de trabalhos a serem desenvolvidos em um futuro próximo, agora que já é sabido que o ferramental baseado em Tabelas de Decisão Adaptativas é perfeitamente viável, em termos computacionais e em termos de modelagem de nicho ecológico.

## VII. CONCLUSÃO

Os dois algoritmos, GARP e ADAPTGARP, se mostraram equivalentes em relação aos resultados de AUC e das áreas potenciais evidenciadas nos mapas. Portanto, pode-se considerar que os resultados obtidos na modelagem de nicho ecológico de ambos são equivalentes. Em termos biológicos, essas diferenças até poderiam ser mais bem analisadas através de outros experimentos com outras metodologias ou organismos, mas o que foi feito neste trabalho, considerando a variedade e a quantidade de testes realizada, já é suficiente para estabelecer que a solução adotada parece ser uma boa base para o desenvolvimento de novas pesquisas em adaptatividade.

Em trabalhos futuros, a solução aqui validada será evoluída de forma a permitir inserir o conhecimento prévio do pesquisador nas Tabelas de Decisão Adaptativas sobre a espécie que está em estudo. Desta forma, será possível controlar melhor o comportamento do algoritmo em determinadas situações, inserir novas funcionalidades relacionadas aos algoritmos genéticos e, como resultado, melhorar a qualidade dos modelos de nicho ecológico através da exploração da tecnologia adaptativa.

## AGRADECIMENTOS

Os autores agradecem à FAPESP – Fundação de Amparo à Pesquisa do Estado de São Paulo – Brazil, pelo apoio financeiro aos projetos openModeller (04/11012-0) e BioAbelha (04/15801-0).



## REFERÊNCIAS

- [1] ARAÚJO, M. B., PEARSON, R. G., THUILLER, W. & Erhard, M. 2005. *Validation of species-climate impact models under climate change*. Global Change Biology v. 11, s/n, p.1504-1513.
- [2] BRAVO, C., NETO, J.J., SANTANA, F.S., SARAIVA, A.M., 2007. *Towards and adaptive implementation of genetic algorithms*. Latin American Workshop on Biodiversity Informatics – INBI 2007 / CLEI 2007 – XXXIII Conferência Latino Americana de Informática. 9–12 Outubro. San José, Costa Rica.
- [3] BRUNDTLAND, G., 1987. *Our Common Future: The World Commission on Environment and Development*. Oxford University Press, Oxford.
- [4] ELITH, J., et. al. 2006. Novel methods improve prediction of species' distributions from occurrence data. *Ecography* v. 29, n. 2, p. 129-151.
- [6] GILDERSLEEVE, T. R. *Decision Tables and Their Practical Application in Data Processing*. Englewood Cliffs, N. J., Prentice Hall, 1970.
- [7] HOLLAND, J. H. 1975. *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Ann Arbor.
- [8] HUTCHINSON, G.E. (1981). *Introducción a la ecología de poblaciones*. Barcelona, Editorial Blume. 492 p.
- [9] HUGHES, M. L., SHANK, R. M., STEIN, E. S. *Decision Tables*. Mide Publications, Management Development Institute, Divisions of Information, Industries, Inc., Wayne, Pennsylvania, 1968.
- [10] HURD, P.D. LINSLEY, E.G. 1964. The squash and gourd bees - genera *Peponapis* and *Xenoglossa* - inhabiting America North of Mexico *Hilgardia* v. 35, p. 375-477
- [11] HURD, P.D. LINSLEY, E.G. 1966. The Mexican squash and gourd bees of the genus *Peponapis* *Ann. of Entomol. Soc. Of America*, v. 59, p.835-51
- [12] HURD, P.D. LINSLEY, E.G. 1967. South American squash and gourd bees of the genus *Peponapis* *Ann. of Entomol. Soc. Of America*, v. 60, p. 647-61
- [13] HURD, P. D. Jr., LINSLEY, E. G. and WHITAKER, T. W. 1971. Squash and gourd bees (*Peponapis*, *Xenoglossa*) and the origin of the cultivated *Cucurbita*. *Evolution* 25, 218-234.
- [14] LOBO, J. M., JIMÉNEZ-VALVERDE, A. & REAL, R. 2008. AUC: a misleading measure of the performance of predictive distribution models. *Global Ecology and Biogeography* v. 17, n. 2, p. 145-151.
- [15] NETO, J. J., *Adaptive Rule-Driven Devices – General Formulation and Case Study*. Lecture Notes in Computer Science. Watson, B.W. and Wood, D. (Eds.): Implementation and Application of Automata 6th International Conference, CIAA 2001, Vol. 2494, Pretoria, South Africa, July 23-25, Springer-Verlag, 2001, pp. 234-250.
- [16] NETO, J. J. Um Levantamento da Evolução da Adaptatividade e da Tecnologia Adaptativa. *Revista IEEE América Latina*. Vol. 5, Num. 7, ISSN: 1548-0992, Novembro 2007. (p. 496-505)
- [17] PETERSON, A. T., PAPES, M. & SOBERON, J. 2008. Rethinking receiver operating characteristic analysis applications in ecological niche modeling. *Ecological Modelling* v. 213, n. 1, p. 63-72.
- [18] PHILLIPS, S. J., ANDERSON, R. P. & SCHAPIRE, R. E. 2006. Maximum entropy modeling of species geographic distributions. *Ecological Modelling* 190, 231–259.
- [19] POLLACK, S.L., HICKS, H.T., and HARRISON, W.J., *Decision Tables: Theory and Practice*, Wiley, New York, 1971.
- [20] SANTANA, F. S., SIQUEIRA M. F., SARAIVA, A. M. & CORREA, P. L. P. 2008. A reference business process for ecological niche modeling. *Ecological Informatics* v. 3, n. 1, p. 75-86.
- [21] SOBERON, J. and PETERSON, A. T., 2005. Interpretation of models of fundamental ecological niches and species' distributional areas. 1-10.
- [22] STOCKWELL, D. R. B., BEACH, J. H., STEWART, A., VORONTSOV, G., VIEGLAIS, D. and PEREIRA, R. S., 2006. The use of the GARP genetic algorithm and internet grid in the Lifemapper world atlas as species biodiversity. *Ecological Modelling*.
- [23] STOCKWELL, D. R. B. & PETERSON, A. T. 2002. Effects of sample size on accuracy of species distribution models. *Ecological Modelling* 148, 1–13.
- [24] SWETS, K. A. 1988. Measuring the accuracy of diagnostic systems. *Science* 240, 1285–1293. WCED (World Commission on Environment and Development) 1987. *Our common future*. Oxford Univ. Press.

## Autores

**Renata Luiza Stange** é mestranda em Engenharia Elétrica (Área de concentração: Computação e Sistemas Digitais) pela Escola Politécnica da Universidade de São Paulo. Especialista em Administração de Sistemas de Informação pela Universidade Federal de Lavras em Ciências e Bacharel em Análise de Sistemas pela Universidade Estadual do Centro-Oeste do Paraná.

**Fabiana Soares Santana** é doutoranda em Engenharia Elétrica (Área de concentração: Computação e Sistemas Digitais) pela Escola Politécnica da Universidade de São Paulo. Mestre em Ciências (Matemática Aplicada - área de concentração: Ciência da Computação) e Bacharel em Ciência da Computação pelo Instituto de Matemática e Estatística da Universidade de São Paulo. Professora do Centro Universitário da FEI e professora do Centro Universitário UNIFIEO. 17 anos de experiência docente, em instituições de renome nacional e internacional. 10 anos de experiência profissional em TI, com ocupação de cargos de liderança, incluindo a gerência de tecnologia e desenvolvimento de sistemas em instituições financeiras de médio e grande porte e a coordenação de projetos de caráter internacional.

**João José Neto** é graduado em Engenharia de Eletricidade (1971), mestre em Engenharia Elétrica (1975), doutor em Engenharia Elétrica (1980) e livre-docente (1993) pela Escola Politécnica da Universidade de São Paulo. Atualmente, é professor associado da Escola Politécnica da Universidade de São Paulo e coordena o LTA – Laboratório de Linguagens e Tecnologia Adaptativa do PCS – Departamento de Computação e Sistemas Digitais da EPUSP. Tem experiência na área de Ciência da Computação, com ênfase nos Fundamentos da Engenharia da Computação, atuando principalmente nos seguintes temas: dispositivos adaptativos, tecnologia adaptativa, autômatos adaptativos, e em suas aplicações à Engenharia de Computação, particularmente em sistemas de tomada de decisão adaptativa, análise e processamento de linguagens naturais, construção de compiladores, robótica, ensino assistido por computador, modelagem de sistemas inteligentes, processos de aprendizagem automática e inferências baseadas em tecnologia adaptativa.

**Antonio M. Saraiva** é professor titular no Depto. De Engenharia de Computação e Sistemas Digitais da Escola Politécnica da Universidade de São Paulo (EPUSP), Brasil. Graduiu-se em Engenharia Elétrica pela EPUSP (1980) e em Agronomia pela ESALQ-USP (1987). É Mestre (1993), Doutor (1998) e Livre-Docente (2003) pela EPUSP. Fundador (1989) e coordenador do Laboratório de Automação Agrícola (LAA) da EPUSP. Suas áreas de interesse abrangem as diversas aplicações das tecnologias da informação e comunicação ao agronegócio e ambiente. É membro da Associação Brasileira de Agroinformática (SBIAgro), da qual foi presidente (2004-2007), da Associação Brasileira de Engenharia Agrícola (SBEA) e da American Society of Agricultural and Biological Engineers (ASABE).