

結合序優化與計算最佳預算分配的進化式演算法

洪士程

朝陽科技大學資訊工程系
schong@cyut.edu.tw

洪辰儒

朝陽科技大學資訊工程系
s9827628@cyut.edu.tw

摘要

在本篇文章中，我們提出一個結合序優化(OO)和計算最佳預算分配(OCBA)的進化式演算法(EA)，來解決具有巨大的離散解空間的即時隨機模擬最佳化組合問題，以找出一個足夠好的解。我們使用一個事先離線訓練好的類神經網路(ANN)作為替代模型，搭配進化式演算法在所考慮的問題中獲得一個足夠好的子集解，接著使用計算最佳預算分配的技術繼續尋找最佳的解，最後便可獲得足夠好的解。另外，我們將提出的演算法應用在飯店訂房限制(HBL)收益最大化問題中，這是一個隨機模擬最佳化組合問題。為測試我們的方法所獲得足夠好的解在解的品質與計算效能上的表現，將我們的方法與另外二個方法，粒子群演算法(PSO)與演化策略(ES)進行比較，發現我們方法的表現的確超越其他方法。

關鍵詞：進化式演算法，序優化，類神經網路，隨機模擬，飯店訂房限制。

Abstract

In this paper, we propose an evolutionary algorithm (EA) assisted by a surrogate model in the framework of ordinal optimization (OO) and optimal computing budget allocation (OCBA) to solve the real-time combinatorial stochastic simulation optimization problem with huge discrete solution space for a good enough solution. For the purpose of real-time application, we use an off-line trained artificial neural network (ANN) as the surrogate model. We apply EA assisted by the trained ANN to the considered problem to obtain a subset of good enough solutions S . Also for the sake of real-time application, we use OCBA technique to find the best solution in S , and which is the obtained good enough solution. We apply the proposed algorithm to a hotel

booking limit (HBL) problem, which is a combinatorial stochastic simulation optimization problem. To demonstrate the computational efficiency of our approach and the quality of the obtained solution, we have compared with two competing methods, the particle swarm optimization (PSO) algorithm and the evolution strategies (ES). Test results show that our approach is an excellent alternative for the combinatorial stochastic simulation optimization problem.

Keywords: evolution algorithm, ordinal optimization, artificial neural network, stochastic simulation, hotel booking limit.

1. 前言

近年來，有越來越多的研究方法在探索解的方法，在即時的工程最佳化問題，例如機翼翼形形狀設計問題、電腦輔助設計(CAD)問題、計算電磁問題、隨機模擬最佳化問題和組合最佳化問題等等需費時的計算目標函數值，搭配替代模型的輔助進化式演算法[9,10,11,15]針對這類問題提供了一個可行的解決方法，其中 Nain 和 Deb 使用粗糙和精確模型[14]來加快計算效率和改善解決方法的品質。Schmit 和 Lipson 使用協同進化的技術同時處理替代模型的近似值範圍與準確的預測適應值[17]。Zhou 等人提出一個彌集演算法，這個演算法包含了全域和區域替代模型加速最佳化的進化過程[21]。Tenne 和 Armfield 提出一個使用變量全域模型和區域替代模型的彌集最佳化架構[18]，根據半徑式函數網路來解決機翼翼形形狀設計最佳化的問題。Guimaraes 等人提出由兩個策略組成的彌集演算法，由調整黑箱函數的精確性和區域搜索的近似值去解決電磁裝置中電腦輔助設計的問題[6]。Ting 和 Liao 使用彌集演算法解決一個使用 k -覆蓋的配置問題以延長無線感測器網路的壽命[19]。Chen 等人提出一個混合式演算法解決即時資源限制項目調度問題[3]。在現有的方法當中[6,9,10,11,14,15,17,18,21]，即時的替代模

型通常透過目標函數的評估以探求準確性，因此 Jin 指出為了減少計算時間，利用少數的目標函數進行評估，可能導致全域模型粗糙並且獲得不好的解，因為沒有全面掌握到問題[8]，若是評估更精確的目標函數來改進這項缺點則會增加計算的時間，因此要建造即時的替代模型準確度的計算時間是需要付出代價的。因此節省計算時間是上述所提到的方法的目的，其中大多數重點都集中在工程設計的問題，除了[3]之外並沒有要求即時的應用。

在這篇論文中，我們考慮一個具有巨大離散解空間的隨機模擬最佳化組合問題，只允許非常有限的計算來解決這個問題，同時在巨大離散解空間中，樣本解經常是建構替代模型所考慮的，上述兩個思考方向可避免我們建構即時替代模型需要面對的問題，因此離線建構的替代模型雖不一定準確，但是卻可拿來實際應用。由於嚴格的計算預算限制，我們將提出一個方案解決即時應用的最佳化問題，使用有限的計算時間去得到一個足夠好的解。處理費時的最佳化問題是序優化(OO)的目標[7]，序優化的基本方法敘述如下，S 代表從替代模型的 N 個解當中得到的足夠好的解，G 代表實際足夠好的子集解，為替代模型中最好的 N%，並且有很高的可靠度，S 與 G 至少包含 $k(\geq 1)$ 個交集。因此序優化第一階段是使用一個替代模型去計算目標函數並且評估 N 個解以及挑選最好的|S|個解，第二階段是使用費時的精確模型去評估這 S 個解，一般來說從|S|個解均勻的獲得優秀且足夠好的解，然而在第二階段的序優化需要更多的計算時間，因此必須同時顧及準確的解和最適合的計算時間，這個結果顯示序優化和普通啟發式演算法的差別。

然而當離散解空間非常巨大並且沒有限制 N 數量時，使用第一階段序優化的替代模型評估每個解是不合適的，為了解決這個困難我們使用替代輔助進化式演算法來計算替代模型的效率，對評估足夠好的解的子集解做搜索，此外為了加快即時計算的應用，我們使用事先離線訓練好的類神經網路(ANN)做為第一階段序優化的替代模型，而且採用最佳計算預算分配(OCBA)的技術[1,2]去挑選 S 當中的最佳解，在第二階段序優化使用精確的替代模型去評估 S 中的每一個解，最後得到一個足夠好的解。

我們以下列的方式來編排這篇論文，在第二節敘述隨機模擬最佳化組合問題，在第三節說明結合序優化和計算最佳預算分配的進化

式演算法，在第四節將提出的演算法應用在飯店訂房限制(HBL)收益最大化問題，在第五節做一個結論。

2. 問題陳述

典型的隨機模擬最佳化組合問題可表示如下：

$$\min_{\theta \in \Theta} E[J(\theta)] \quad (1)$$

Θ 表示離散隨機解空間， $E[J(\theta)]$ 為目標函數值可透過模擬程序的評估所獲得。為了得到準確的 $E[J(\theta)]$ ，模擬程序需要經過一個大規模且重複的 L (~ 10000) 次隨機模擬，目標函數值可用下式求得 $E[J(\theta)] = \frac{1}{L} \sum_{l=1}^L J_l(\theta)$ ，其中 $J_l(\theta)$ 表示第 l 次隨機模擬的 $J(\theta)$ 值。假設所考慮的問題包含 n 個離散變量，並且每個變量有 k 可能值，則離散解空間 Θ 將包含有 k^n 個可能解 θ ，只要 n 與 k 的值非常大，離散解空間將會非常的巨大。

3. 結合序優化與計算最佳預算分配的進化式演算法

3.1 利用類神經網路輔助基因演算法

為了得到(1)式足夠好的解，結合序優化與計算最佳預算分配的進化式演算法 包含了三個步驟，第一個步驟是建構替代模型來評估一個給定的 θ 其目標函數值 $E[J(\theta)]$ 的近似值，在這裡採用離線訓練的類神經網路來建構這個模型。第二步驟是使用類神經網路輔助基因演算法獲得一個足夠好的子集 S，第三步驟是使用計算最佳預算分配技術從 S 中找到足夠好的解。

3.1.1 類神經網路替代模型

目前有各種不同的技術[8]可用來近似一個系統的輸入與輸出之間的關係，像是多項式回歸、支持向量機、類神經網路、半徑式函數網路等都常常拿來使用，其中近似值技術的採用需視真正問題而定。在這篇論文使用類神經網路，因為類神經網路對於連續變量函數非常準確並且對於離散項目模擬系統的輸入與輸出的關係有近似的能力[4]。

為了可以即時應用，使用離線訓練的類神經網路，一旦這個類神經網路訓練完畢，我們可以透過簡單的運算獲得這個類神經網路的輸出。對於這離線訓練的類神經網路，首先均勻的挑選 M 個解 θ ，而 M 大約是 16641，之後使用精確的模型評估這 M 個解 θ 的目標函數值 $E[J(\theta)]$ ，再來收集這 M 個解的輸入與輸出配對 $(\theta, E[J(\theta)])$ ，使用這些配對來訓練的類神經網路且調整權重值。一旦類神經網路訓練完畢，我們可以輸入任何的 θ 去獲得相對應的 $E[J(\theta)]$ 輸出，以這種方式可以避免漫長的隨機模擬程序，對於給定的 θ 可透過替代模型來評估這目標函數的近似值。當離散解空間設定為 $|\Theta|=10^{30}$ 時，考慮到 99% 的置信水平以及 1% 的置信區間[13]，透過樣本大小的方程式可求出樣本大小 $M=16641$ 。

3.1.2 類神經網路輔助基因演算法

一旦類神經網路訓練完畢，可以使用基因演算法對進化族群當中的每個個體求出近似適應值(目標值)。結合序優化與計算最佳預算分配的進化式演算法的第二個步驟，是透過類神經網路的輔助，使用基因演算法[5]挑選離散解，因為基因演算法對於所考慮的問題很合適，其中基因演算法的細節將在第四節中詳加介紹，我們設置族群個體總數為 Q ，當基因演算法收斂後，我們會在 Q 個解當中選擇最好的 $|S|$ 個解。

3.1.3 使用計算最佳預算分配技術獲得足夠好的解

使用計算最佳預算分配的技術去挑選 S 中的最佳解，如何對樣本解進行選擇與評估是關鍵所在，計算最佳預算分配技術就是在隨機模擬的環境下選擇與評估樣本解的有效方法，透過合理的分配計算量，對於關鍵的樣本解分配較多的計算量，而不重要的樣本解則分配較少的計算量，如此對於真正好的樣本解可獲得更大的正確選擇機率。因此，計算的複雜度便可以大大地降低。所以給定計算子集 T 為在 S 中挑選的最佳解，透過重複模擬的措施，並且設置 N_i 代表重複模擬的數量分配，而這計算最佳預算分配的最佳分配標準 T 從 $N_1, N_2, \dots, N_{|S|}$ 並且 $N_1 + N_2 + \dots + N_{|S|} = T$ ，可挑選出 S 中可

靠度最大的最佳解，由 Chen 等人制定了以下的演算法去挑選 S 中的最佳解[1,2]。

計算最佳預算分配演算法

步驟 0：執行 n_0 的重複模擬對於 S 中的所有解，設置 $l = 0$ 。

步驟 1：假設 $N_1 + N_2 + \dots + N_{|S|} \geq T$ ，則停止。

步驟 2：增加 Δ 新的數值來重複模擬，並且對這重複模擬做新的分配，利用

$$\frac{N_i^{l+1}}{N_j^{l+1}} = \left(\frac{\sigma_i(\bar{J}_b - \bar{J}_j)}{\sigma_j(\bar{J}_b - \bar{J}_i)} \right)^2 \text{ 在所有 } i \neq j \neq b \text{ 和}$$

$$N_b^{l+1} = \sigma_b \sqrt{\sum_{i=1, i \neq b}^k \left(\frac{N_i^{l+1}}{\sigma_i} \right)^2} \text{ 當 } b = \arg \min_i \bar{J}_i。$$

4. 應用實例

這裡提出的演算法可以運用到即時晶圓測試問題[12]，但是其中沒有使用計算最佳預算分配技術也沒提供效能分析，為了使有興趣的研究者能獲得更多，我們挑選了一個比較普及的問題，就是這飯店訂房限制(HBL)收益最大化問題，這問題發表在網站 SimOpt [16]並且包含應用實例。

4.1 回顧飯店訂房限制(HBL)問題

飯店的主要收入來自客人的入住，飯店訂房的核心概念是收益管理，飯店可保留部份的房間讓高價值的客戶使用。假設飯店的房間數量為 C ，並且飯店提供標準房價和折扣房價兩種價格，標準房價和折扣房價入住每晚的支付金額分別訂定為 p_r 和 p_d 。對於停留的時間和到達的日期設置不同的訂單組合，假設任何訂單如果有折扣價的房間可用那麼客戶會優先選擇折扣價的房間，為了避免這種情形發生，我們將設置每個訂單與支付金額是一個商品，因此可以產生以下 56 個商品(28 個不同的訂單皆提供標準房價和折扣房價)，可用這種方式來滿足一個星期的房間價值 (14 個周一抵達，12 個週二抵達，...，2 個周日抵達)：

1. 住宿一晚，周一抵達折扣價。
2. 住宿一晚，周一抵達標準價。
3. 住宿兩晚，周二抵達折扣價。
4. 住宿兩晚，周二抵達標準價。
- ：

55. 住宿一晚，周日抵達折扣價。

56. 住宿一晚，周日抵達標準價。

對於給定的住宿訂單，飯店的收入等於(支付金額) $\times$ (停留時間)，對於每個訂單的到達流程設定為具有一個固定的到達率 λ_i 的卜以松過程， $i=1, \dots, 28$ 。關於訂單的停止住宿時間設定，屬於周一晚上到達的訂單最遲至周二凌晨三點就停止住宿，屬於周二晚上到達的訂單最遲至周三凌晨三點就停止住宿，以此類推。

飯店的收入管理問題，主要是挑選出預設的訂房限制值 $(\theta_1, \dots, \theta_{56})$ 可使期望收益達到最大。根據這個模型，使訂房限制具有控制價格的能力，可以售出任何特定的商品，也表示可以接受對商品要求的最大數量，必須注意的是訂房限制並不代表每個商品預留的房間數，而是表示這商品可用的房間數，並且所有商品都使用相同資源會有較高的訂房限制。

設置訂房限制的操作與接受訂單的運作可由以下說明。

訂單接受的運作：商品 i 的需求僅當 $\theta_i > 0$ 時才會接受，否則就拒絕，當商品 i 的需求被接受，必須更新使用商品 i 的所有訂房限制所需要的資源，同時減少現有資源。

對每個 θ_i 的訂房限制可表示為 $1 \leq \theta_i \leq C$ ，房間數量上限值 C 是確保不會產生房間過剩，而下限值 1 是確保每一個商品至少有一間可以提供的房間。

假設模擬的開始時間是接受一周前的訂單，也就是 $t = -168$ 小時一直到一周結束的周日晚上 $t = 168$ 小時，因此飯店訂房限制問題的收益最大化問題可以制定如下：

$$\begin{aligned} \max_{\theta \in \Theta} & E[J(\theta)] \\ \text{subject to} & 1 \leq \theta_i \leq C, i = 1, \dots, 56 \end{aligned} \quad (2)$$

其中 $E[J(\theta)]$ 代表在訂房限制為

$\theta = [\theta_1 \ \theta_2 \ \dots \ \theta_{56}]^T$ 時的飯店期望收入。

4.2 套用結合序優化與計算最佳預算分配的進化式演算法

4.2.1 建構近似模型

為了建構類神經網路做為近似模型，使用了一個三層的類神經網路來組成，其中包含 56 個輸入神經元，90 個隱藏神經元和一個輸出神經元，如圖一所示，其中 $\omega_{i,j}$ $i = 1, \dots, 56$,

$j = 1, \dots, 90$ 和 β_k , $k = 1, \dots, 90$ 表示為權重，對應的 56 個神經元在輸入層代表 θ ，輸出層的一個神經元代表 $E[J(\theta)]$ ，隱藏層神經元使用正切雙彎曲函數，輸出層的活化函數為線性函數。




圖 1. 三層類神經網路

假設 28 個訂單的到達率 λ_i , $i = 1, \dots, 28$ 是事先給定的，對於這個給定的到達率，首先在離散的解空間 Θ 隨機挑選 $M = 16641$ 個 θ 向量訓練類神經網路，對於每個挑選的 θ ，使用精確模型來評估飯店期望收入 $E[J(\theta)]$ 。定義精確的模型 $E[J(\theta)]$ 是利用

$$E[J(\theta)] = \frac{1}{L} \sum_{l=1}^L J_l(\theta), \quad J_l(\theta) \text{ 表示在訂房限制}$$

向量為 θ 且從 $t = -168$ 小時到 $t = 168$ 小時的收益， L 是在接受訂單起使用卜以松過程與給定的到達率，經過重複的模擬程序所獲得，平均而言 L 是 (~ 10000) 重複的模擬。接著使用上述 M 個輸入與輸出配對 $(\theta, E[J(\theta)])$ ，並且採用一個典型訓練演算法，像是

LM(Levenberg-Marquardt)演算法 [18] 來訓練這類神經網路並且調整權重。當類神經網路訓練完畢，對於給定的 θ 可以從類神經網路的輸出獲得近似目標值 $E[J(\theta)]$ 。

4.2.2 使用類神經網路輔助基因演算法

採用基因演算法來描述在 Θ 中的所有變數是相當簡單的，因為向量 θ 的每個部份都是一個整數，我們從 $|Q|$ 開始，假設 2000，從 Θ 中隨機挑選變數當做初始群體的染色體，適應值是每個染色體 θ 的近似值 $E[J(\theta)]$ ，可由類神經網路輸出獲得。染色體在群體中挑選母體是使用輪盤挑選方式隨機挑選，染色體使用一個

單點交叉方式做交叉交配其交配率為 $p_c (=0.7)$ 。突變的突變率為 $p_m (=0.02)$ ，來做突變的操作。當迭代數目超過 40 基因演算法就會停止，當基因演算法收斂時，在 $|Q|$ 中的最終排名染色體透過適應值挑選出最好的 $|S|$ 個染色體，即構成足夠好的訂房限制向量子集解。

4.2.3使用計算最佳預算分配技術從 S 中獲得足夠好的解

在所獲得的 S 中使用在 3.1.3 節中介紹的最佳計算預算分配技術挑選最好的 θ ，這個 θ 即是一個足夠好的解。

4.3 測試結果

測試範例考慮在 4.1 節介紹的 56 個商品，共有 28 個訂單其到達率表示如下， $[\lambda_1, \dots, \lambda_{28}] = \frac{1}{168} [10.5 \ 12.0 \ 5.2 \ 10.5 \ 2.3 \ 2.1 \ 2.0 \ 5.2 \ 10.5 \ 2.1 \ 2.1 \ 2.1 \ 1.2 \ 3]$ 房間/小時，房間數量上限值 $C=100$ ，標準價格 $p_r=200$ ，折扣價格 $p_d=100$ ，模擬的時間長度是 336 個小時，在一周前開始接受訂單，也就是 $t=-168$ 小時至周日晚上 $t=168$ 小時。將 $|S|$ 設定為 1000，基因演算法和最佳計算預算分配技術使用的參數設定如下， $|Q|=2000$ ， $p_c=0.7$ ， $p_m=0.02$ ， $n_0=20$ 和 $\Delta=20$ ，參數 T 使用在最佳計算預算分配的技術中，其數值為 $T=625000$ ，基於一個 16:1 縮短計算時間所使用的最佳計算預算分配[2]，當 $|S|=1000$ ，可利用 $T = \frac{S \times L}{16}$ 來確定 T 的值。

表 1 顯示測試範例所獲得足夠好的解 $\hat{\theta}$ 和相對應的預期收益 $E[J(\hat{\theta})]$ ，和耗費的計算時間，我們的方法計算時間在兩分鐘內完成算是非常的快。為測試我們的方法所獲得足夠好的解在解的品質與計算效能上的表現，將我們的方法與另外二個方法，粒子群演算法(PSO)與演化策略(ES)，採用精確的模型進行比較。在期望收入比較方面，我們的方法獲得 24803，比 PSO 的 23117 與 ES 的 22989 都要來的大。在計算時間比較方面，我們的方法花費 1.73 分鐘，遠比 PSO 的 82.73 分鐘與 ES 的 77.53 分鐘要來的小。從以上數據顯示我們的方法在解的品質與計算效能上的表現的確超越其他二個方法。

5. 結論

在這篇文章中我們提出輔助進化式演算法搭配替代模型，這個演算法結合了序優化和計算最佳預算分配方法，來解決具有巨大的離散解空間的隨機模擬組合最佳化問題，以求得一個足夠好的解。將我們提出的演算法套用在飯店訂房限制收益最大化問題當中，可以獲得足夠好的解。為測試我們的方法所獲得足夠好的解在解的品質與計算效能上的表現，將我們的方法與另外二個方法，粒子群演算法(PSO)與演化策略(ES)進行比較，發現我們方法的表現的確超越其他方法。

表 1 足夠好的解 $\hat{\theta}$ ，相對應的期望收入 $E[J(\hat{\theta})]$ 與計算時間。

Test Method	Good enough booking limit vector θ	$E[J(\hat{\theta})]$	CPU times (min.)
Our approach	[62 9 56 75 77 22 55 71 70 8 36 7 76 11 78 32 60 89 92 19 52 3 82 2 78 29 61 60 61 7 12 79 75 25 72 4 68 93 76 10 35 27 88 62 18 50 75 13 83 38 63 11 22 26 88 31]	24803	1.73
PSO	[65 61 17 94 57 15 59 72 57 2 16 94 89 26 36 34 20 88 8 96 79 9 83 75 78 66 26 62 53 68 39 15 83 26 91 4 88 81 92 22 49 45 56 5 73 11 81 27 40 22 6 57 33 10 12 29]	23117	82.78
ES	[37 69 26 26 23 51 92 21 53 24 61 5 61 57 19 62 99 87 95 11 37 98 66 8 74 19 90 75 67 31 86 73 73 12 43 46 87 70 80 79 69 24 94 42 54 16 35 5 92 25 42 95 66 96 19 49]	22989	77.53

致謝

本論文係由國科會計劃 NSC99-2628-E-324-001 贊助。

參考文獻

[1] C.H. Chen, D. He, M. Fu, L.H. Lee, Efficient simulation budget allocation for selecting an optimal subset, INFORMS J. Comput., 20 (4) (2008) 579-595.

- [2] C.H. Chen, J. Lin, E. Yucesan, S.E. Chich, Simulation budget allocation for further enhancing the efficiency of ordinal optimization, *Discret. Event Dyn. Syst.-Theory Appl.*, 10 (3) (2000) 251-270.
- [3] W. Chen, Y.J. Shi, H.F. Teng, X.P. Lan, L.C. Hu, An efficient hybrid algorithm for resource-constrained project scheduling, *Inf. Sci.*, 180 (6) (2010) 1031-1039.
- [4] B. Dengiz, C. Alabas-Uslu, O. Dengiz, Optimization of manufacturing systems using a neural network metamodel with a new training approach, *J. Oper. Res. Soc.*, 60 (9) (2009) 1191-1197.
- [5] D.E. Goldberg, K. Sastry, *Genetic Algorithms: The Design of Innovation*, 2nd ed., Springer-Verlag, New York, 2010.
- [6] F.G. Guimaraes, D.A. Lowther, J.A. Ramirez, Analysis of approximation-based memetic algorithms for engineering optimization, In: Y. Tenne and C.K. Goh (Eds.), *Computational Intel. in Expensive Opti. Prob., ALO 2*, Springer-Verlag, Berlin Heidelberg, 2010, pp. 163-191.
- [7] Y.C. Ho, Q.C. Zhao, Q.S. Jia, *Ordinal optimization: Soft optimization for hard problems*, Springer-Verlag, New York, 2007.
- [8] Y.C. Jin, A comprehensive survey of fitness approximation in evolutionary computation, *Soft Comput.*, 9 (1) (2005) 3-12.
- [9] Y.C. Jin, M. Olhofer, B. Sendhoff, A framework for evolutionary optimization with approximate fitness functions, *IEEE Trans. Evol. Comput.*, 6 (5) (2002) 481-494.
- [10] M.K. Karakasis, K.C. Giannakoglou, On the use of metamodel-assisted, multi-objective evolutionary algorithms, *Eng. Optimiz.*, 38 (8) (2006) 941-957.
- [11] D. Lim, Y.C. Jin, Y.S. Ong, B. Sendhoff, Generalizing surrogate-assisted evolutionary computation, *IEEE Trans. Evol. Comput.*, 14 (3) (2010) 329-355.
- [12] S.Y. Lin, S.C. Horng, Application of an ordinal optimization algorithm to the wafer testing process, *IEEE Trans. Syst., Man Cybern.-Part A, Syst. and Humans*, 36 (6) (2006) 1229-1234.
- [13] D.S. Moore, G.P. McCabe, B. Craig, *Introduction to the Practice of Statistics*, 6th ed., W.H. Freeman and Company, New York, 2007.
- [14] P.K.S. Nain, K. Deb, Computationally effective search and optimization procedure using coarse-to-fine approximations, In *Proc. IEEE Congr. Evol. Comput.*, Canberra, Australia, 2003, pp. 2081-2088.
- [15] I. Paenke, E. Branke, Y.C. Jin, Efficient search for robust solutions by means of evolutionary algorithms and fitness approximation, *IEEE Trans. Evol. Comput.*, 10 (4) (2006) 405-420.
- [16] SimOpt.org, Booking limits at a hotel: Full. [Online]. (2009) Available: <http://www.simopt.org/problems/integer/unconstrained.php>
- [17] M.D. Schmidt, H. Lipson, Coevolution of fitness predictors, *IEEE Trans. Evol. Comput.*, 12 (6) (2008) 736-749.
- [18] Y. Tenne, S.W. Armfield, A framework for memetic optimization using variable global and local surrogate models, *Soft Comput.*, 13 (8-9) (2009) 781-793.
- [19] C.K. Ting, C.C. Liao, A memetic algorithm for extending wireless-sensor network lifetime, *Inf. Sci.*, 180 (24) (2010) 4818-4833.
- [20] B.M. Wilamowski, H. Yu, Improved computation for Levenberg-Marquardt training, *IEEE Trans. Neural Netw.*, 21 (6) (2010) 930-937.
- [21] Z. Zhou, Y.S. Ong, P.B. Nair, A.J. Keane, K.Y. Lum, Combining global and local surrogate models to accelerate evolutionary optimization, *IEEE Trans. Syst. Man Cyber., C, Appl. Rev.*, 37 (1) (2007) 66-76.