

# Aprendizaje por reforzamiento aplicado al operador de cruce en algoritmos genéticos con codificación real.

D. Ortiz-Boyer, A. de Haro-García y R. del Castillo-Gomariz

*Resumen*— Diseñar algoritmos genéticos que aprendan a lo largo del proceso evolutivo a generar individuos que favorezcan un adecuado equilibrio entre exploración y explotación del espacio de búsqueda es un objetivo ambicioso a la vez que complejo. En este artículo abordaremos una primera aproximación a este problema aplicando aprendizaje por reforzamiento al operador de cruce. Para ello recompensaremos a cada individuo en función de la bondad de los hijos que ha generado a lo largo de su vida. Si la aptitud de los hijos de un padre suele ser buena, es que posee características potencialmente buenas y, por tanto, se debe fomentar la generación de individuos que hereden dichas características. Esta filosofía la hemos incorporado en diferentes operadores de cruce y hemos evaluado los resultados en el conjunto de problemas de optimización continua propuesto en el IEEE Congress on Evolutionary Computation (CEC'05).

*Palabras clave*— Aprendizaje por reforzamiento, operadores de cruce, algoritmos genéticos con codificación real, optimización en entornos continuos.

## I. INTRODUCCIÓN

Una de las cuestiones más importantes que se plantea al diseñar un Algoritmo Genético (AG) es la elección de los métodos de generación de nuevos individuos. Éstos deben garantizar un adecuado equilibrio entre exploración y explotación del espacio de búsqueda. No obstante este punto de equilibrio es muy dependiente del problema. En general, en problemas unimodales se potencia la componente explotadora, mientras que en problemas multimodales, no separables, epistáticos y con dimensionalidad alta, se potencia la componente exploradora. Esta regla, no cuantificable, es la que en general el diseñador utiliza para definir los diferentes parámetros del AG que inciden sobre el equilibrio entre exploración y explotación.

¿Cómo se puede aprender cual es el punto de equilibrio más adecuado para cada problema? El aprendizaje por reforzamiento [1], en adelante RL (del inglés *reinforcement learning*), consiste en aprender a realizar la acción más correcta ante una determinada situación con el objetivo de maximizar una función de recompensa. A diferencia del aprendizaje su-

pervisado, en el que el aprendizaje se lleva a cabo a partir de un conjunto de entrenamiento, el aprendizaje por reforzamiento está basado en la interacción de un sistema (agente) con su medio.

El objetivo sería diseñar un sistema que aprendiera a generar nuevos individuos que resolvieran un problema dado, sin más información que el estado actual de la población y el problema a resolver. No obstante la complejidad de este objetivo lo hace inabordable en la fase de investigación en la que nos encontramos.

En este trabajo nos centraremos en el estudio del operador de cruce en Algoritmos Genéticos con Codificación Real (AGCR), cuyas características los hacen muy apropiados para resolver problemas de optimización en entornos continuos. En general estos operadores tienen una serie de parámetros a través de los cuales se establecen un equilibrio entre exploración y explotación.

El objetivo que nos marcamos en este trabajo es utilizar RL para que el AGCR aprenda a establecer de forma automática, en función del problema y la población, que parámetros son los más adecuados para el operador de cruce. Para definir la función de recompensa hemos estudiado diferentes técnicas para evaluar la bondad de un individuo en función de los hijos que ha generado. Si la aptitud de los hijos de un padre suele ser buena, es que posee características potencialmente buenas y, por tanto, se debe fomentar la generación de individuos que hereden dichas características.

En este trabajo aplicaremos una primera aproximación de la idea anterior a los cruces BLX [2], SBX [3], CIXL2 [4] y CIXL1 [5] y estudiaremos sus resultados en el conjunto de pruebas propuesto en el IEEE Congress on Evolutionary Computation (CEC'05) [6].

## II. APRENDIZAJE POR REFORZAMIENTO

Aprender por reforzamiento es aprender qué hacer, cómo relacionar situaciones con acciones, de manera que una señal, usualmente numérica, (denominada recompensa) sea maximizada. El aprendizaje por reforzamiento caracteriza un problema de aprendizaje. Cualquier método adecuado para resolver una instancia de este problema, se considera un

Este trabajo ha sido financiado en parte por el proyecto de excelencia P07-TIC-02682 de la Junta de Andalucía y el proyecto TIN2008-03151 de la CICYT

Dept. de Informática y Análisis Numérico. Campus de Rabanales, Edif. A. Einstein. Universidad de Córdoba. 14071-Córdoba E-mail: {dortiz, i22hagaa, rcastillo}@uco.es

método de aprendizaje por reforzamiento. El agente se encarga de aprender qué acción se debe ejecutar en función del ambiente. Por lo tanto, existe un compromiso entre exploración y explotación. Para encontrar una buena recompensa, el agente tiene un sesgo a preferir acciones que ha experimentado en el pasado, pero para que estas acciones sean adecuadas, el agente tuvo que explorar otras posibilidades. Si se adopta una sola de estas estrategias, es muy probable que el problema de aprendizaje no sea resuelto. Obsérvese que el RL considera explícitamente el problema completo de diseñar un agente que interactúa con un medio incierto. Esto contrasta con el enfoque tradicional de la Inteligencia Artificial (IA), donde el aprendizaje es generalmente uno de los componentes del agente. Teóricamente RL es más cercano a la teoría óptima de control y la aproximación estadística, que a la lógica usada tradicionalmente en Inteligencia Artificial.

Además del agente y el medio, es posible identificar cuatro componentes principales de un sistema de aprendizaje por reforzamiento:

- **Política:** Define la manera de comportarse de un agente en un tiempo dado. Puede verse como una aplicación entre los estados del ambiente que el agente percibe y las acciones que toma, cuando se encuentra en esos estados. Este elemento es central porque por sí solo es suficiente para determinar el comportamiento. Por lo general, las políticas deben ser estocásticas.
- **Función de reforzamiento:** Define la meta en un problema de RL, al aplicar cada percepción del agente (estado del ambiente o par estado, acción) a un número (recompensa) que indica como de deseable es ese estado. El objetivo del agente es maximizar la recompensa recibida a largo plazo. De esta forma, la función define qué eventos son buenos y malos para el agente por lo que la función es necesariamente inalterable por las acciones del agente. Debe, sin embargo, servir como base para alterar la política, por ejemplo, si una acción elegida por la política recibe una recompensa muy baja, la política debe cambiarse para elegir una acción diferente en esa situación. Una función de reforzamiento por lo general es estocástica.
- **Función de evaluación:** Mientras que la función de reforzamiento indica lo que es bueno en lo inmediato, la función de evaluación lo hace a largo plazo. Puede verse como la cantidad total de recompensa que el agente espera recibir en el tiempo, partiendo de un estado en particular. La recompensa determina la bondad inmediata de un estado, este valor representa la bondad a largo plazo del mismo, tomando en cuenta los estados a los que podría conducir. La mayoría de los algoritmos RL operan estimando la función de evaluación.
- **Modelo del ambiente:** Los modelos mimetizan el medio. Dado un estado y una acción, el modelo debería predecir el estado resultante y la recompensa próxima. Los modelos se utilizan para planear, es

decir, decidir sobre un curso de acción que involucra situaciones futuras, antes de que estas se presenten. La incorporación de modelos y planificación en RL es un desarrollo reciente, el RL clásico puede verse como la anti-planificación. Ahora es claro que los métodos RL están estrechamente relacionados a los métodos de programación dinámica. Así los algoritmos RL pueden verse como una mezcla entre las estrategias ensayo-error y la planificación deliberativa.

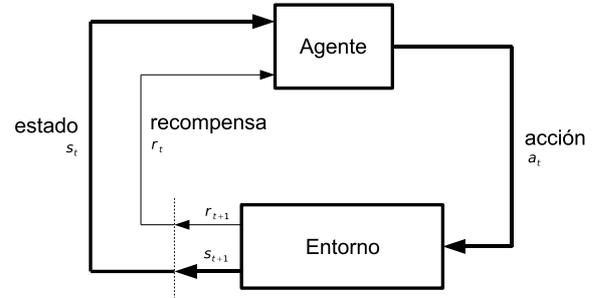


Fig. 1. Diagrama de interacción agente-entorno.

La dinámica del aprendizaje por reforzamiento la podemos ver en la Figura 1. El agente y el entorno interactúan durante una secuencia  $t = 0, 1, 2, 3, \dots$ . Para cada  $t$ , el agente recibe alguna representación del estado,  $s_t \in S$ , donde  $S$  es el conjunto de posibles estados, y en base a esto selecciona una acción,  $a_t \in A(s_t)$ , donde  $A(s_t)$  es el conjunto de acciones posibles en el estado  $s_t$ . A continuación, en parte como consecuencia de su acción, el agente recibe una recompensa,  $r_{t+1} \in R$ , y se pasa a un nuevo estado,  $s_{t+1}$ .

### III. APLICACIÓN AL OPERADOR DE CRUCE

Consideremos los individuos padres y el resto de la población como el ambiente o entorno del sistema, cuyo estado es modificado cuando se generan los descendientes. El agente debe cuantificar el carácter explorador o explotador de los nuevos individuos a través de los parámetros del cruce. Si un individuo genera buenos individuos es indicativo de que se encuentra en una zona prometedora del espacio de búsqueda, incluso aunque su aptitud sea mala en comparación con la del resto de la población. Esta idea fomenta la exploración de nuevas zonas, ya que individuos con mala aptitud pueden generar descendientes que hereden sus características, si estas han demostrado ser buenas en los hijos anteriormente generados.

Para fomentar la generación de descendientes en las proximidades de aquellos padres que potencialmente generan mejores hijos hay que definir la función de reforzamiento que vamos a utilizar para el cálculo de la recompensa que debe recibir un padre cuando genera un descendiente. Esta es una de las partes fundamentales en el aprendizaje por reforzamiento y de ella depende en buena medida que el agente aprenda o no.

Sea  $\beta$  un conjunto de  $N$  individuos que forman una población, como primera aproximación, para cada hijo  $\beta^s = \{\beta_1^s, \beta_2^s, \dots, \beta_i^s, \dots, \beta_p^s\}$  con  $p$  genes que sea mejor que el peor de los individuos de la población la recompensa se calcula como sigue:

$$r = \frac{f(\beta^s) - \overline{f(\beta)}}{|\overline{f(\beta)}|} \quad (1)$$

Donde  $f(\beta^s)$  es la aptitud del hijo, y  $\overline{f(\beta)}$  es la aptitud media de la población. A cada padre  $\beta^{f1} = \{\beta_1^{f1}, \beta_2^{f1}, \dots, \beta_i^{f1}, \dots, \beta_p^{f1}\}$  y  $\beta^{f2} = \{\beta_1^{f2}, \beta_2^{f2}, \dots, \beta_i^{f2}, \dots, \beta_p^{f2}\}$ , se le asignará una recompensa ponderada en función de la distancia euclídea  $D$  con respecto al hijo (ecuación 2).

$$r_{\beta^{f1}} = r * \frac{D(\beta^{f1}, \beta^s)}{D(\beta^{f1}, \beta^s) + D(\beta^{f2}, \beta^s)} \quad (2)$$

$$r_{\beta^{f2}} = r * \frac{D(\beta^{f2}, \beta^s)}{D(\beta^{f1}, \beta^s) + D(\beta^{f2}, \beta^s)}$$

Las recompensas obtenidas por cada individuo se utilizarán para modular los parámetros del operador de cruce correspondiente. Para comprobar los resultados de esta política la implementaremos en los cruces que a continuación explicaremos.

#### A. Cruce BLX

Crea un hijo  $\beta^s = \{\beta_1^s, \beta_2^s, \dots, \beta_i^s, \dots, \beta_p^s\}$ , donde  $\beta_i^s$  es elegido aleatoriamente en el intervalo  $[\beta_{min} - I \cdot \alpha, \beta_{max} + I \cdot \alpha]$ . Siendo  $\beta_{max} = \max(\beta_i^{f1}, \beta_i^{f2})$ ,  $\beta_{min} = \min(\beta_i^{f1}, \beta_i^{f2})$  y  $I = \beta_{max} - \beta_{min}$  [2]. Para  $\alpha = 0,5$ , la probabilidad de que los genes de los hijos tomen valores dentro o fuera del intervalo definido por los padres es la misma.

##### A.1 Cruce BLXRL

En este cruce  $\beta_i^s$  es elegido aleatoriamente en el intervalo  $[\beta_{min} - I \cdot \alpha_{min}, \beta_{max} + I \cdot \alpha_{max}]$ , donde

$$\alpha_{min} = 0,5 + \frac{\overline{r}_{\beta^{f_{min}}}}{\overline{r}_{\beta^{f_{max}}} + \overline{r}_{\beta^{f_{min}}}} \quad (3)$$

$$\alpha_{max} = 0,5 + \frac{\overline{r}_{\beta^{f_{max}}}}{\overline{r}_{\beta^{f_{max}}} + \overline{r}_{\beta^{f_{min}}}}$$

Donde  $\overline{r}_{\beta^{f_{min}}}$  es la recompensa media del padre cuyo gen tiene un valor menor  $\beta_{min} = \min(\beta_i^{f1}, \beta_i^{f2})$ , y  $\overline{r}_{\beta^{f_{max}}}$  es la recompensa media del padre cuyo gen tiene un valor mayor  $\beta_{max} = \max(\beta_i^{f1}, \beta_i^{f2})$ .

#### B. Cruce SBX

El cruce SBX (Simulated Binary Crossover) fue propuesto por Deb [3] e intenta emular el efecto del cruce en un punto usado con representación binaria. Este cruce genera dos hijos:

$$\beta^{s1} = \frac{1}{2}[(1 + B_k)\beta^{f1} + (1 - B_k)\beta^{f2}] \quad (4)$$

$$\beta^{s2} = \frac{1}{2}[(1 - B_k)\beta^{f1} + (1 + B_k)\beta^{f2}],$$

donde  $B_k \geq 0$  es un valor generado según la función de densidad

$$p(B) = \begin{cases} \frac{1}{2}(\eta + 1)B^\eta, & \text{si } 0 \leq B \leq 1 \\ \frac{1}{2}(\eta + 1)\frac{1}{B^{\eta+2}}, & \text{si } B > 1 \end{cases} \quad (5)$$

Esta distribución puede ser obtenida fácilmente a partir de una distribución uniforme  $u(0, 1)$  mediante la transformación

$$B(u) = \begin{cases} (2u)^{\frac{1}{\eta+1}}, & \text{si } u \leq \frac{1}{2} \\ \left(\frac{1}{2(1-u)}\right)^{\frac{1}{\eta+1}}, & \text{si } u > \frac{1}{2} \end{cases} \quad (6)$$

El parámetro  $\eta$  establece la amplitud de la distribución con la que se generan los descendientes. En general  $\eta = 5$  establece un buen compromiso entre exploración y explotación para un amplio rango de problemas [7] [8].

#### B.1 Cruce SBXRL

Este cruce genera dos hijos:

$$\beta^{s1} = \frac{1}{2}[(1 + B_{f1})\beta^{f1} + (1 - B_{f1})\beta^{f2}] \quad (7)$$

$$\beta^{s2} = \frac{1}{2}[(1 - B_{f2})\beta^{f1} + (1 + B_{f2})\beta^{f2}].$$

Para generar  $B_{f1}$  utilizaremos  $\eta_{f1} = \overline{r}_{\beta^{f1}}$ , y para  $B_{f2}$  utilizaremos  $\eta_{f2} = \overline{r}_{\beta^{f2}}$ . Como este cruce genera un hijo en las proximidades de cada padre, para cada hijo se utiliza un parámetro diferente cuyo valor será igual a la media de las recompensas del padre.

#### C. Cruce CIXL2

Sea  $\beta$  un conjunto de  $N$  individuos que forman una población y  $\beta^* \subset \beta$  el conjunto de los  $n$  mejores individuos con respecto a su aptitud. Si consideramos que cada uno de los genes de los individuos de  $\beta^*$  están normalmente distribuidos, podemos definir tres individuos asociados al extremo inferior (CILL), superior (CIUL) y media (CIM) del intervalo de confianza de los valores de sus genes:

$$CILL_i = \overline{\beta}_i - t_{n-1, \alpha/2} \frac{S_{\beta_i}}{\sqrt{n}};$$

$$CIUL_i = \overline{\beta}_i + t_{n-1, \alpha/2} \frac{S_{\beta_i}}{\sqrt{n}};$$

$$CIM_i = \overline{\beta}_i$$

siendo  $\overline{\beta}_i$ ,  $i = 1, \dots, n$ , la media de cada gen,  $S_{\beta_i}$  la desviación típica,  $t_{n-1, \alpha/2}$  un valor obtenido de a partir de la distribución  $t$  de Student con  $n - 1$  grados de libertad y  $1 - \alpha$  la probabilidad de que la media pertenezca a su intervalo de confianza.

Los individuos CILL y CIUL dividen el dominio de cada gen,  $D_i \equiv [a_i, b_i]$ , en tres subintervalos  $I^L$ ,  $I^{CI}$  y  $I^R$ , tal que  $D_i \equiv I^L \cup I^{CI} \cup I^R$  y  $I^L \equiv [a_i, CILL_i]$ ;  $I^{CI} \equiv [CILL_i, CIUL_i]$ ;  $I^R \equiv [CIUL_i, b_i]$ .

Este cruce crea a partir de un individuo de la población  $\beta^f = (\beta_0^f, \beta_1^f, \dots, \beta_i^f, \dots, \beta_p^f) \in \beta$ , y un individuo CILL, CIUL y CIM, un único hijo  $\beta^s$  de la siguiente forma:

- $\beta_i^f \in I^L$ : Si la aptitud de  $\beta^f$  es mayor que la de CILL entonces  $\beta_i^s = u(\beta_i^f - CILL_i) + \beta_i^f$ , sino  $\beta_i^s = u(CILL_i - \beta_i^f) + CILL_i$ .
- $\beta_i^f \in I^{CI}$ : Si la aptitud de  $\beta^f$  es mayor que la de CIM entonces  $\beta_i^s = u(\beta_i^f - CIM_i) + \beta_i^f$ , sino  $\beta_i^s = u(CIM_i - \beta_i^f) + CIM_i$ .
- $\beta_i^f \in I^R$ : Si la aptitud de  $\beta^f$  es mayor que la de CIUL entonces  $\beta_i^s = u(\beta_i^f - CIUL_i) + \beta_i^f$ , sino  $\beta_i^s = u(CIUL_i - \beta_i^f) + CIUL_i$  (figure 1).

donde  $u$  es un número aleatorio perteneciente al intervalo  $[0,1]$ . Ambos parámetros  $1 - \alpha$  y  $n$ , son los encargados de establecer un equilibrio entre exploración y explotación en función de las características de localización y dispersión de los mejores individuos de la población. En un trabajo anterior [4] se encontró que valores de  $(1 - \alpha) = 0,7$  y  $n = 5$  garantizan un equilibrio muy adecuado para problemas de diferente tipología.

#### C.1 Cruce CIXL2RL

En este cruce incorporamos la recompensa media del padre  $\bar{r}_{\beta^f}$  como un nuevo parámetro a tener en cuenta cuando la aptitud  $\beta^f$  sea mayor que la del padre virtual con el que le corresponda cruzarse en función de su posición. Así  $\beta^s$  será creado de la siguiente forma:

- $\beta_i^f \in I^L$ : Si la aptitud de  $\beta^f$  es mayor que la de CILL entonces  $\beta_i^s = \bar{r}_{\beta^f}(\beta_i^f - CILL_i) + \beta_i^f$ , sino  $\beta_i^s = u(CILL_i - \beta_i^f) + CILL_i$ .
- $\beta_i^f \in I^{CI}$ : Si la aptitud de  $\beta^f$  es mayor que la de CIM entonces  $\beta_i^s = \bar{r}_{\beta^f}(\beta_i^f - CIM_i) + \beta_i^f$ , sino  $\beta_i^s = u(CIM_i - \beta_i^f) + CIM_i$ .
- $\beta_i^f \in I^R$ : Si la aptitud de  $\beta^f$  es mayor que la de CIUL entonces  $\beta_i^s = \bar{r}_{\beta^f}(\beta_i^f - CIUL_i) + \beta_i^f$ , sino  $\beta_i^s = u(CIUL_i - \beta_i^f) + CIUL_i$  (figure 1).

#### D. Cruce CIXL1

En este cruce se utiliza la mediana  $M_{\beta_i^*}$  como estimador de localización y no se hace ninguna suposición con respecto a la distribución de los genes. El intervalo de confianza se calcula como sigue:

$$[\beta_{i(k+1)}^*, \beta_{i(n-k)}^*] \quad (8)$$

donde  $P(Bin(n, \frac{1}{2}) \leq k) = \alpha/2$  determina  $k$

Así, los genes de los padres virtuales se obtienen como sigue:

$$\begin{aligned} CILL_i &= \beta_{i(k+1)}^* \\ CIUL_i &= \beta_{i(n-k)}^* \\ CIM_i &= M_{\beta_i^*} \end{aligned} \quad (9)$$

La estrategia para generar los descendientes es la misma que se emplea en el cruce CIXL2. Este cruce utiliza un intervalo de confianza no paramétrico o independiente de la distribución de los genes, ya que éste se determina mediante una distribución binomial, sin hacer ninguna hipótesis en relación a la distribución de los genes. Valores de  $(1 - \alpha) = 0,7$  y  $n = 5$  se muestran muy adecuados para problemas de diferente tipología [5].

#### D.1 Cruce CIXL1RL

Consiste en aplicamos la misma filosofía del cruce CIXL2RL al cruce CIXL1.

## IV. EXPERIMENTOS

Para evaluar la bondad de esta estrategia de aprendizaje hemos utilizado el conjunto de pruebas propuesto en la sesión especial de optimización continua del IEEE Congress on Evolutionary Computation (CEC'05) [6] compuesto por 25 problemas de minimización con diferentes características. Cada problema es resuelto para tres dimensiones diferentes  $d = 10, 30, 50$ . El máximo número de evaluaciones será igual a  $10000 * d$  y para obtener los resultados se harán 25 ejecuciones de cada experimento.

Usaremos un AGCR de estado estacionario [9] con una población inicial aleatoria de 50 individuos que será reinicializada y duplicada si la diferencia entre la aptitud del mejor individuo de esa generación y el de la generación  $10 + 30 * d$  anterior es menor que  $10^{-12}$ . Utilizaremos una probabilidad de cruce  $p_c = 0,6$ , mutación no uniforme [10] con probabilidad  $p_g = 0,05$ , y una selección por torneo de dos. Para cada cruce se utilizan los parámetros recomendados anteriormente citados:  $alpha = 0,5$  para BLX,  $\eta = 5$  para SBX, y  $(1 - \alpha) = 0,7$ ,  $n = 5$  para CIXL2 y CIXL1.

## V. RESULTADOS

En las tablas I y II podemos ver los resultados obtenidos para las 25 funciones. El signo + indica que el resultado del cruce que usa RL es mejor que el original. El test de signos realizado para cada pareja indica que no existen diferencias significativas. No obstante en muchos de los problemas los resultados obtenidos aplicando RL mejoran los obtenidos con el cruce original.

La aplicación de RL es especialmente beneficiosa en el cruce CIXL1RL en el que en 41 ocasiones se mejoran los resultados obtenidos con el cruce original. Para dimensión 10 mejora los resultados en 15 de las 25 funciones, para dimensión 30 en 6, y para dimensión 50 en 13 funciones. En ningún caso las diferencias son significativas.

En las funciones híbridas F16-F25, el cruce CIXL1RL consigue mejoras en 16 de las 30 pruebas realizadas. Para dimensión 10 y 50 mejora los resultados en 6 de las 10 funciones, y para dimensión 30

sólo en 2 funciones. En ningún caso las diferencias son significativas.

Para las funciones F6-F25 y dimensión 10 G-CMA-ES siempre mejora los resultados obtenidos con CIXL1RL. Para F8, F15 y F25 CIXL1RL mejora a DE, y para F15, F21 y F23 a K-PCX. Para dimensión 30 los resultados mejoran, superando CIXL1RL a G-CMA-ES en las funciones F12 y F24; a DE en las funciones F8, F9, F11, F14, F15 y F25; y a K-PCX en F13, F14, F15, F21, F22 y F23.

## VI. CONCLUSIONES Y TRABAJOS FUTUROS

La aplicación del aprendizaje por reforzamiento a la evolución de un algoritmo evolutivo con el objetivo de que este aprenda a generar descendientes que establezcan un equilibrio adecuado entre exploración y explotación, es un objetivo ambicioso y complejo.

En este primer trabajo hemos restringido su aplicación al operador de cruce. Para ello hemos recompensado aquellos individuos que generan mejores hijos. Si un padre genera buenos hijos es que posee características potencialmente buenas y, por tanto, se debe fomentar la generación de individuos que hereden dichas características.

No obstante la concreción de esta recompensa y su aplicación al operador de cruce plantea muchas dificultades. En este trabajo mostramos una primera aproximación cuyos resultados, aun sin ser concluyentes, constituyen un punto de partida en el estudio de RL aplicado a algoritmos evolutivos.

La utilización de diferentes funciones de recompensa, evaluación y políticas de actuación aplicadas tanto al operador de cruce como al de mutación abre un campo muy amplio de investigación.

## REFERENCIAS

- [1] R. S. Sutton and A. G. Barto, *Reinforcement Learning: An Introduction*, MIT Press, 1998.
- [2] L. J. Eshelman and J. D. Schaffer, "Real-coded genetic algorithms and interval-schemata," in *Foundation of Genetic Algorithms 2*, L. Darrell Whitley, Ed., San Mateo, 1993, pp. 187C3.3.7:1–C3.3.7:8.–202, Morgan Kaufmann.
- [3] K. Deb and R. B. Agrawal, "Simulated binary crossover for continuous search space," *Complex Systems*, vol. 9, pp. 115–148, 1995.
- [4] D. Ortiz-Boyer, C. Hervás-Martínez, and N. García-Pedrajas, "CIXL2: A crossover operator for evolutionary algorithms based on population features," *Journal of Artificial Intelligence Research*, vol. 24, pp. 1–48, July 2005.
- [5] D. Ortiz-Boyer, C. Hervás-Martínez, and N. García-Pedrajas, "Robust confidence intervals applied to crossover operator for real-coded genetic algorithms," *Soft Computing*, vol. 12, pp. 809, 833 2008.
- [6] *IEEE Congress on Evolutionary Computation (CEC'05)*, Napier University, Edinburgh, UK, September 2005. IEEE Press.
- [7] K. Deb and H. Beyer, "Self-adaptive genetic algorithms with simulated binary crossover," *Evolutionary Computation*, vol. 9, no. 2, pp. 195–219, 2001.
- [8] F. Herrera, M. Lozano, and A. M. Sánchez, "A taxonomy for the crossover operator for real-coded genetic algorithms: An experimental study," *International Journal of Intelligent Systems*, vol. 18, pp. 309–338, 2003.
- [9] A. Rogers and A. Prügel-Bennett, "Modelling the dynamics of steady-state genetic algorithms," in *Foundations of Genetic Algorithms*, W. Banzhaf and C. Reeves, Eds., pp. 57–68. Morgan Kaufmann, San Francisco, 1999.

- [10] Z. Michalewicz, *Genetic Algorithms + Data Structures = Evolution Programs*, Springer-Verlag, New York, 1992.

TABLA I

RESULTADOS OBTENIDOS PARA CADA PROBLEMA UTILIZANDO LOS CRUCES BLX, BLXRL, SBX Y SBXRL.

Función	Tamaño	BLX		BLXRL		SBX		SBXRL		
		Media	Desv.Típ.	Media	Desv.Típ.	Media	Desv.Típ.	Media	Desv.Típ.	
F1	10	7.711E-07	2.354E-06	8.891E-09	9.486E-10	+ 1.814E-01	2.844E-01	8.733E-02	1.055E-01	+
	30	1.679E-05	2.964E-05	1.092E-06	3.080E-06	+ 9.971E-02	5.110E-02	1.187E-01	7.521E-02	-
	50	1.555E-04	1.586E-04	2.477E-05	7.168E-05	+ 4.150E-01	2.195E-01	4.550E-01	1.869E-01	-
F2	10	1.815E+02	1.983E+02	3.765E-01	1.168E+00	+ 6.895E+02	5.305E+02	8.385E+02	7.644E+02	-
	30	3.125E+03	1.235E+03	6.463E+02	2.965E+02	+ 7.398E+03	2.573E+03	8.064E+03	2.987E+03	-
	50	1.193E+04	3.769E+03	8.559E+03	3.082E+03	+ 1.878E+04	5.937E+03	1.725E+04	4.205E+03	+
F3	10	1.865E+06	2.981E+06	9.435E+05	7.437E+05	+ 4.377E+06	3.146E+06	4.832E+06	4.023E+06	-
	30	1.427E+07	4.361E+06	7.006E+06	2.408E+06	+ 2.169E+07	7.797E+06	2.346E+07	1.033E+07	-
	50	2.722E+07	8.709E+06	1.820E+07	6.773E+06	+ 4.942E+07	1.431E+07	4.925E+07	1.667E+07	+
F4	10	5.620E+02	4.306E+02	1.698E+02	1.868E+02	+ 2.687E+03	1.479E+03	2.474E+03	1.450E+03	+
	30	1.840E+04	5.549E+03	1.566E+04	7.463E+03	+ 3.112E+04	9.718E+03	3.500E+04	6.710E+03	-
	50	5.489E+04	1.302E+04	5.997E+04	1.204E+04	- 7.753E+04	1.881E+04	7.971E+04	1.289E+04	-
F5	10	4.071E+01	1.050E+02	4.373E+01	3.946E+02	- 1.272E+03	7.511E+02	1.586E+03	1.412E+03	-
	30	4.197E+03	1.029E+03	5.380E+03	1.787E+03	- 9.194E+03	1.592E+03	1.037E+04	2.503E+03	-
	50	1.038E+04	1.707E+03	1.070E+04	2.303E+03	- 1.663E+04	2.677E+03	1.809E+04	3.277E+03	-
F6	10	1.133E+03	2.292E+03	1.104E+03	2.110E+03	+ 2.191E+03	3.308E+03	1.529E+03	2.786E+03	+
	30	2.357E+03	2.982E+03	1.937E+03	3.077E+03	+ 3.937E+03	4.990E+03	2.163E+03	3.403E+03	+
	50	2.793E+03	4.405E+03	2.551E+03	3.900E+03	+ 2.500E+03	3.554E+03	2.071E+03	3.131E+03	+
F7	10	6.862E-01	3.540E-01	6.264E-01	6.167E-01	+ 2.135E+00	2.002E+00	2.305E+00	1.755E+00	-
	30	1.029E+00	1.790E-01	1.818E-01	1.856E-01	+ 2.039E+00	8.160E-01	2.119E+00	9.970E-01	-
	50	1.280E+00	2.028E-01	7.158E-01	2.562E-01	+ 4.098E+00	1.550E+00	3.458E+00	1.490E+00	+
F8	10	2.037E+01	7.356E-02	2.038E+01	9.169E-02	- 2.035E+01	7.457E-02	2.036E+01	7.697E-02	-
	30	2.095E+01	5.453E-02	2.096E+01	5.436E-02	- 2.088E+01	1.776E-01	2.084E+01	1.669E-01	+
	50	2.112E+01	4.765E-02	2.114E+01	4.306E-02	- 2.114E+01	1.350E-01	2.110E+01	1.036E-01	+
F9	10	1.761E+00	1.191E+00	2.300E+00	1.189E+00	- 2.091E+00	1.179E+00	2.435E+00	1.517E+00	-
	30	9.795E+00	3.136E+00	1.410E+01	4.512E+00	- 1.195E+01	3.704E+00	1.163E+01	3.227E+00	-
	50	3.254E+01	5.960E+00	4.221E+01	9.798E+00	- 3.506E+01	6.994E+00	3.595E+01	6.232E+00	-
F10	10	1.831E+01	9.596E+00	2.153E+01	1.061E+01	- 3.823E+01	1.339E+01	3.479E+01	1.119E+01	+
	30	7.149E+01	3.149E+01	6.796E+01	2.325E+01	+ 1.839E+02	3.860E+01	1.763E+02	4.702E+01	+
	50	1.106E+02	2.603E+01	1.133E+02	2.680E+01	- 3.228E+02	6.762E+01	3.090E+02	7.411E+01	+
F11	10	7.152E+00	1.695E+00	6.042E+00	1.872E+00	+ 7.091E+00	1.312E+00	7.877E+00	1.439E+00	-
	30	2.519E+01	5.055E+00	2.132E+01	3.538E+00	+ 2.979E+01	2.548E+00	3.305E+01	3.372E+00	-
	50	4.702E+01	1.352E+01	3.913E+01	4.638E+00	+ 5.421E+01	5.270E+00	5.584E+01	7.180E+00	-
F12	10	6.403E+02	6.299E+02	8.216E+02	1.013E+03	- 2.528E+03	2.296E+03	3.021E+03	2.986E+03	-
	30	2.964E+04	1.857E+04	3.677E+04	2.326E+04	- 4.658E+04	3.037E+04	3.738E+04	1.558E+04	+
	50	1.129E+05	6.936E+04	1.507E+05	6.646E+04	- 1.471E+05	6.550E+04	1.596E+05	6.479E+04	-
F13	10	8.036E-01	3.176E-01	7.444E-01	3.969E-01	+ 1.100E+00	4.888E-01	1.189E+00	4.921E-01	-
	30	3.128E+00	7.325E-01	2.655E+00	7.995E-01	+ 3.241E+00	7.535E-01	3.321E+00	8.178E-01	-
	50	6.526E+00	1.201E+00	8.004E+00	2.194E+00	- 7.301E+00	1.411E+00	6.868E+00	1.291E+00	+
F14	10	3.714E+00	1.472E-01	3.686E+00	2.661E-01	+ 3.696E+00	1.741E-01	3.713E+00	2.170E-01	-
	30	1.337E+01	3.126E-01	1.345E+01	1.664E-01	- 1.315E+01	2.132E-01	1.305E+01	3.133E-01	+
	50	2.318E+01	2.153E-01	2.299E+01	5.204E-01	+ 2.270E+01	4.082E-01	2.254E+01	4.536E-01	+
F15	10	2.749E+02	1.455E+02	3.201E+02	1.663E+02	- 2.910E+02	1.495E+02	2.764E+02	1.372E+02	+
	30	2.911E+02	6.229E+01	3.203E+02	8.694E+01	- 3.494E+02	1.057E+02	3.697E+02	1.006E+02	-
	50	2.332E+02	4.487E+01	2.762E+02	8.292E+01	- 2.961E+02	9.565E+01	2.992E+02	8.582E+01	-
F16	10	1.328E+02	2.474E+01	1.418E+02	2.871E+01	- 2.025E+02	3.124E+01	2.117E+02	4.884E+01	-
	30	1.946E+02	7.824E+01	2.612E+02	1.654E+02	- 2.562E+02	7.331E+01	2.659E+02	7.638E+01	-
	50	2.196E+02	1.158E+02	1.927E+02	1.269E+02	+ 2.722E+02	8.268E+01	2.990E+02	8.272E+01	-
F17	10	1.517E+02	2.950E+01	1.611E+02	3.410E+01	- 2.222E+02	4.890E+01	2.192E+02	4.200E+01	+
	30	2.103E+02	8.730E+01	1.957E+02	8.747E+01	+ 3.081E+02	7.068E+01	3.140E+02	4.984E+01	-
	50	2.502E+02	9.447E+01	1.925E+02	9.826E+01	+ 3.645E+02	6.671E+01	3.588E+02	6.963E+01	+
F18	10	8.796E+02	1.232E+02	8.975E+02	1.038E+02	- 9.552E+02	8.209E+01	9.612E+02	9.650E+01	-
	30	9.100E+02	1.961E+00	9.107E+02	3.111E+00	- 9.260E+02	7.524E+00	9.383E+02	1.219E+01	-
	50	9.329E+02	6.444E+00	9.350E+02	6.272E+00	- 9.670E+02	1.216E+01	9.765E+02	2.243E+01	-
F19	10	8.567E+02	1.263E+02	8.562E+02	1.524E+02	+ 9.466E+02	7.138E+01	1.003E+03	7.631E+01	-
	30	9.109E+02	2.952E+00	9.110E+02	3.859E+00	- 9.261E+02	1.061E+01	9.419E+02	2.111E+01	-
	50	9.342E+02	7.167E+00	9.357E+02	9.452E+00	- 9.662E+02	1.251E+01	9.763E+02	2.133E+01	-
F20	10	8.772E+02	1.108E+02	8.457E+02	1.714E+02	+ 9.050E+02	8.673E+01	9.791E+02	8.029E+01	-
	30	9.100E+02	2.180E+00	9.108E+02	3.409E+00	- 9.302E+02	9.478E+00	9.452E+02	2.171E+01	-
	50	9.341E+02	4.739E+00	9.354E+02	9.462E+00	- 9.661E+02	1.255E+01	9.830E+02	2.373E+01	-
F21	10	7.052E+02	2.507E+02	7.519E+02	2.890E+02	- 1.048E+03	2.276E+02	9.479E+02	3.113E+02	+
	30	5.107E+02	5.363E+01	5.837E+02	2.025E+02	- 6.600E+02	2.679E+02	6.849E+02	2.678E+02	-
	50	8.496E+02	2.448E+02	1.015E+03	2.353E+00	- 7.054E+02	2.607E+02	8.083E+02	2.648E+02	-
F22	10	7.656E+02	9.784E+01	7.982E+02	4.519E+01	- 8.725E+02	4.621E+01	8.695E+02	3.832E+01	+
	30	9.448E+02	1.938E+01	9.170E+02	2.675E+01	+ 9.847E+02	3.201E+01	9.802E+02	4.080E+01	+
	50	9.356E+02	1.558E+01	9.191E+02	1.663E+01	+ 9.518E+02	2.848E+01	9.513E+02	2.902E+01	+
F23	10	9.813E+02	2.985E+02	8.338E+02	2.937E+02	+ 9.656E+02	3.007E+02	1.054E+03	2.723E+02	-
	30	5.350E+02	3.992E+00	6.146E+02	1.640E+02	- 7.162E+02	2.276E+02	6.279E+02	1.821E+02	+
	50	6.088E+02	8.562E+01	1.018E+03	1.842E+00	- 6.859E+02	2.109E+02	6.820E+02	4.197E+02	+
F24	10	2.000E+02	4.729E-02	2.768E+02	1.746E+02	- 5.072E+02	3.519E+02	5.253E+02	3.384E+02	-
	30	2.049E+02	2.440E+01	5.543E+02	3.713E+02	- 2.634E+02	2.190E+02	2.446E+02	1.697E+02	+
	50	2.008E+02	3.942E+00	8.585E+02	3.124E+02	- 6.705E+02	4.230E+02	6.643E+02	4.197E+02	+
F25	10	2.036E+02	1.519E+01	2.240E+02	8.307E+01	- 4.783E+02	3.318E+02	5.373E+02	3.472E+02	-
	30	2.120E+02	6.000E+01	6.558E+02	3.719E+02	- 2.767E+02	2.263E+02	2.746E+02	2.193E+02	+
	50	2.000E+02	3.548E-05	6.094E+02	4.061E+02	- 6.349E+02	4.259E+02	5.000E+02	4.076E+02	+
Test de signos (win/draw/loss)					Test de signos (win/draw/loss)					
33/0/42 p-valor=0.356					31/0/44 p-valor=0.165					

TABLA II

RESULTADOS OBTENIDOS PARA CADA PROBLEMA UTILIZANDO LOS CRUCES CIXL2, CIXL2RL, CIXL1 Y CIXL1RL.

Función	Tamaño	CIXL2		CIXL2RL		CIXL1		CIXL1RL	
		Media	Desv.Típ.	Media	Desv.Típ.	Media	Desv.Típ.	Media	Desv.Típ.
F1	10	8.495E-09	2.225E-09	8.248E-09	2.181E-09	+ 8.296E-09	2.364E-09	1.144E-05	5.715E-05
	30	4.261E-07	3.417E-07	1.049E-06	1.628E-06	- 4.421E-08	5.458E-08	1.648E-08	1.225E-08
	50	1.234E-05	9.050E-06	4.686E-05	4.437E-05	- 5.217E-07	3.951E-07	1.779E-07	1.345E-07
F2	10	8.379E-01	1.243E+00	3.347E-01	4.174E-01	+ 1.038E+01	1.820E+01	8.599E+00	1.390E+01
	30	4.664E+02	2.254E+02	5.285E+02	2.957E+02	- 1.449E+03	6.682E+02	1.450E+03	7.341E+02
	50	2.659E+03	6.505E+02	3.973E+03	1.418E+03	- 8.304E+03	3.795E+03	7.889E+03	3.149E+03
F3	10	8.574E+05	6.034E+05	7.432E+05	4.724E+05	+ 1.110E+06	1.058E+06	6.150E+05	5.457E+05
	30	8.363E+06	3.134E+06	8.105E+06	2.161E+06	+ 8.396E+06	2.575E+06	8.030E+06	2.650E+06
	50	1.753E+07	6.631E+06	1.774E+07	6.145E+06	- 1.678E+07	4.991E+06	1.549E+07	5.529E+06
F4	10	1.085E+03	6.985E+02	1.196E+03	9.829E+02	- 1.450E+03	9.040E+02	1.635E+03	1.150E+03
	30	2.292E+04	3.962E+03	2.293E+04	6.618E+03	- 3.519E+04	6.017E+03	3.300E+04	5.401E+03
	50	5.996E+04	9.435E+03	6.296E+04	1.010E+04	- 9.346E+04	1.597E+04	1.006E+05	1.774E+04
F5	10	2.620E+02	5.200E+02	4.053E+02	7.083E+02	- 9.111E+01	1.510E+02	2.616E+01	6.864E+01
	30	8.704E+03	1.712E+03	7.955E+03	2.101E+03	+ 9.984E+03	1.701E+03	9.831E+03	1.901E+03
	50	1.784E+04	3.093E+03	1.722E+04	2.836E+03	+ 2.010E+04	3.389E+03	2.021E+04	3.405E+03
F6	10	1.536E+02	2.334E+02	1.140E+02	1.797E+02	+ 3.940E+01	6.897E+01	6.335E+01	9.527E+01
	30	2.774E+02	3.081E+02	1.618E+02	2.154E+02	+ 1.378E+02	1.445E+02	1.127E+02	1.294E+02
	50	2.085E+02	2.263E+02	2.471E+02	2.739E+02	- 2.545E+02	2.805E+02	2.930E+02	4.077E+02
F7	10	1.129E+00	6.362E-01	1.112E+00	1.018E+00	+ 1.294E+00	8.290E-01	1.471E+00	9.111E-01
	30	3.267E-01	2.043E-01	4.779E-01	2.577E-01	- 5.028E-01	2.420E-01	3.300E-01	2.486E-01
	50	9.018E-01	1.778E-01	9.764E-01	1.556E-01	- 6.733E-01	1.951E-01	6.811E-01	2.699E-01
F8	10	2.039E+01	7.464E-02	2.038E+01	8.705E-02	+ 2.038E+01	8.614E-02	2.036E+01	9.830E-02
	30	2.095E+01	1.144E-01	2.097E+01	5.833E-02	- 2.084E+01	2.077E-01	2.076E+01	2.486E-01
	50	2.113E+01	4.295E-02	2.113E+01	3.998E-02	- 2.084E+01	3.235E-01	2.088E+01	3.061E-01
F9	10	3.681E+00	2.027E+00	5.447E+00	4.029E+00	- 3.392E+00	1.373E+00	3.243E+00	1.273E+00
	30	1.444E+01	7.118E+00	2.367E+01	1.339E+01	- 1.698E+01	8.295E+00	1.950E+00	3.305E+00
	50	4.419E+01	1.384E+01	7.230E+01	3.524E+01	- 3.188E+01	1.298E+01	2.979E+01	6.683E+00
F10	10	1.847E+01	7.203E+00	2.317E+01	9.694E+00	- 2.836E+01	1.166E+01	3.004E+01	9.935E+00
	30	1.577E+02	3.966E+01	1.477E+02	4.087E+01	+ 2.168E+02	5.531E+01	1.996E+02	4.414E+01
	50	2.961E+02	5.721E+01	2.658E+02	6.046E+01	+ 3.436E+02	8.595E+01	3.650E+02	8.232E+01
F11	10	7.337E+00	9.996E-01	8.668E+00	1.009E+00	- 7.555E+00	9.782E-01	7.886E+00	1.230E+00
	30	3.091E+01	2.512E+00	3.731E+01	4.505E+00	- 3.163E+01	3.435E+00	3.150E+00	4.294E+00
	50	5.798E+01	4.586E+00	6.890E+01	7.868E+00	- 5.760E+01	4.080E+00	6.035E+01	5.855E+00
F12	10	1.486E+03	1.742E+03	3.746E+03	4.956E+03	- 1.644E+03	1.989E+03	1.376E+03	1.712E+03
	30	4.512E+04	3.512E+04	3.544E+04	2.870E+04	+ 3.751E+04	1.709E+04	3.583E+04	2.422E+04
	50	1.157E+05	4.719E+04	1.447E+05	1.043E+05	- 1.116E+05	6.826E+04	1.344E+05	7.204E+04
F13	10	8.380E-01	4.001E-01	9.366E-01	4.460E-01	- 1.032E+00	6.329E-01	1.094E+00	5.798E-01
	30	3.374E+00	1.109E+00	3.822E+00	1.236E+00	- 3.548E+00	1.133E+00	3.605E+00	1.199E+00
	50	7.278E+00	1.623E+00	9.203E+00	5.004E+00	- 7.215E+00	1.270E+00	7.188E+00	1.737E+00
F14	10	3.836E+00	1.244E-01	3.913E+00	1.564E-01	- 3.763E+00	1.711E-01	3.785E+00	1.517E-01
	30	1.334E+01	4.239E-01	1.333E+01	3.794E-01	+ 1.333E+01	2.581E-01	1.336E+01	2.586E-01
	50	2.272E+01	5.741E-01	2.284E+01	4.627E-01	- 2.290E+01	3.811E-01	2.286E+01	4.774E-01
F15	10	2.882E+02	1.441E+02	2.735E+02	1.503E+02	+ 2.759E+02	1.416E+02	2.408E+02	1.397E+02
	30	3.050E+02	5.512E+01	3.022E+02	6.669E+01	+ 3.423E+02	8.374E+01	3.575E+02	4.222E+01
	50	2.790E+02	9.111E+01	2.892E+02	9.138E+01	- 2.798E+02	9.417E+01	2.694E+02	1.040E+02
F16	10	1.498E+02	1.895E+01	1.412E+02	1.969E+01	+ 1.691E+02	2.299E+01	1.851E+02	2.881E+01
	30	2.336E+02	6.544E+01	2.553E+02	1.006E+02	- 2.989E+02	8.504E+01	2.966E+02	8.147E+01
	50	2.424E+02	7.400E+01	2.475E+02	8.820E+01	- 3.069E+02	7.702E+01	2.911E+02	7.430E+01
F17	10	1.568E+02	2.418E+01	1.586E+02	2.946E+01	- 2.012E+02	2.476E+01	1.875E+02	2.981E+01
	30	3.218E+02	4.546E+01	2.423E+02	4.686E+01	- 3.296E+02	6.130E+01	3.241E+02	6.223E+01
	50	3.086E+02	3.723E+01	2.922E+02	4.985E+01	+ 3.996E+02	6.657E+01	3.942E+02	7.594E+01
F18	10	9.203E+02	9.307E+01	9.222E+02	1.063E+02	- 9.161E+02	9.234E+01	9.322E+02	8.962E+01
	30	9.242E+02	7.781E+00	9.219E+02	7.747E+00	+ 9.238E+02	7.575E+00	9.236E+02	7.651E+00
	50	9.606E+02	1.712E+01	9.666E+02	2.053E+01	- 9.870E+02	3.342E+01	9.811E+02	2.227E+01
F19	10	9.759E+02	6.096E+01	9.472E+02	7.811E+01	+ 8.970E+02	9.116E+01	9.156E+02	8.141E+01
	30	9.252E+02	8.776E+00	9.236E+02	1.245E+01	+ 9.259E+02	6.775E+00	9.222E+02	6.041E+00
	50	9.674E+02	1.841E+01	9.711E+02	3.251E+01	- 9.714E+02	2.385E+01	9.833E+02	3.244E+01
F20	10	9.306E+02	9.235E+01	9.641E+02	6.577E+01	- 9.257E+02	7.654E+01	9.172E+02	7.892E+01
	30	9.271E+02	9.335E+00	9.227E+02	6.773E+00	+ 9.259E+02	7.510E+00	9.237E+02	1.127E+01
	50	9.676E+02	1.689E+01	9.697E+02	2.970E+01	- 9.717E+02	2.003E+01	9.775E+02	2.806E+01
F21	10	9.648E+02	2.821E+02	8.977E+02	2.932E+02	+ 8.403E+02	2.999E+02	9.402E+02	2.785E+02
	30	6.485E+02	2.558E+02	5.888E+02	1.952E+02	+ 7.226E+02	2.732E+02	6.965E+02	2.786E+02
	50	9.383E+02	1.905E+02	9.098E+02	2.011E+02	+ 9.138E+02	1.853E+02	9.469E+02	1.653E+02
F22	10	8.034E+02	1.853E+01	7.980E+02	1.538E+01	+ 8.322E+02	4.133E+01	8.527E+02	4.119E+01
	30	9.675E+02	2.491E+01	9.816E+02	5.366E+01	- 9.723E+02	2.952E+01	9.841E+02	4.491E+01
	50	9.772E+02	2.525E+01	9.840E+02	3.204E+01	- 9.833E+02	3.111E+01	9.817E+02	3.362E+01
F23	10	9.636E+02	2.942E+02	8.865E+02	3.155E+02	+ 1.002E+03	2.865E+02	1.028E+03	2.672E+02
	30	6.457E+02	1.827E+02	5.897E+02	1.097E+02	+ 6.810E+02	2.411E+02	6.718E+02	2.283E+02
	50	9.458E+02	1.179E+02	8.791E+02	1.597E+02	+ 9.329E+02	1.880E+02	1.003E+03	1.126E+02
F24	10	2.051E+02	1.608E+01	2.016E+02	5.000E+00	+ 4.509E+02	3.007E+02	5.031E+02	3.350E+02
	30	2.457E+02	9.407E+01	2.441E+02	1.130E+02	+ 6.385E+02	3.967E+02	5.440E+02	3.965E+02
	50	5.206E+02	4.145E+02	4.694E+02	4.187E+02	+ 8.436E+02	3.695E+02	7.383E+02	4.126E+02
F25	10	2.016E+02	3.712E+00	2.092E+02	2.192E+01	- 4.550E+02	3.195E+02	4.584E+02	2.925E+02
	30	2.288E+02	6.777E+01	2.544E+02	1.686E+02	- 5.285E+02	3.901E+02	6.383E+02	3.968E+02
	50	3.764E+02	3.291E+02	5.029E+02	4.244E+02	- 8.721E+02	3.433E+02	7.379E+02	4.119E+02
Test de signos (win/draw/loss)					Test de signos (win/draw/loss)				
32/0/43 p-valor=0.248					41/0/34 p-valor=0.489				

