

19



OFICINA ESPAÑOLA DE
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 569 777**

51 Int. Cl.:

F41G 7/22 (2006.01)

F41G 7/30 (2006.01)

F41G 9/00 (2006.01)

G05D 1/12 (2006.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

96 Fecha de presentación y número de la solicitud europea: **23.08.2011** **E 11749495 (5)**

97 Fecha y número de publicación de la concesión europea: **06.01.2016** **EP 2609475**

54 Título: **Método y aparato de guía**

30 Prioridad:

23.08.2010 EP 10251478

23.08.2010 GB 201014064

45 Fecha de publicación y mención en BOPI de la traducción de la patente:
12.05.2016

73 Titular/es:

MBDA UK LIMITED (100.0%)

Six Hills Way

Stevenage, Hertfordshire SG1 2DA, GB

72 Inventor/es:

GATE, MARTIN SIMON

74 Agente/Representante:

CARPINTERO LÓPEZ, Mario

ES 2 569 777 T3

Aviso: En el plazo de nueve meses a contar desde la fecha de publicación en el Boletín europeo de patentes, de la mención de concesión de la patente europea, cualquier persona podrá oponerse ante la Oficina Europea de Patentes a la patente concedida. La oposición deberá formularse por escrito y estar motivada; sólo se considerará como formulada una vez que se haya realizado el pago de la tasa de oposición (art. 99.1 del Convenio sobre concesión de Patentes Europeas).

DESCRIPCIÓN

Método y aparato de guía

Campo de la invención

- 5 Esta invención se refiere al campo de guía y, en particular, a un método y aparato para guiar un rastreador hacia un blanco, por ejemplo un objetivo. Más particularmente, la invención se refiere a un método y aparato para guiar un perseguidor a un objetivo con coste esperado mínimo en un sistema en un estado incierto, pero para el que se conocen los costes. Todavía más particularmente, la invención se refiere a un método para guiar un perseguidor hacia un blanco, donde el blanco no se puede caracterizar fácilmente utilizando estadísticas gaussianas.

Técnica anterior

- 10 El problema fundamental en la guía de munición es determinar la trayectoria de vuelo que un misil u otra munición guiada tiene que tomar para alcanzar un objetivo dado. Más específicamente, el problema es determinar los controles que deberían aplicarse a la munición durante su vuelo para alcanzar el objetivo, por ejemplo determinar la aceleración lateral que se necesita para alcanzar la trayectoria de vuelo deseada.

- 15 Los métodos clásicos de guía implican seleccionar una ley geométrica que gobierne la trayectoria de vuelo, por ejemplo guía de la línea-de-visión, persecución pura o navegación paralela, y entonces determinar y aplicar a la munición el control que se necesita en cualquier momento dado durante su vuelo, para reducir al mínimo el error entre el estado actual (por ejemplo, posición, velocidad) de la munición y el estado ideal determinado por la ley de guía. Para el caso de la navegación paralela, la ley de guía correspondiente más comúnmente utilizada es la navegación proporcional (PN). La navegación paralela es la regla de soporte constante, de manera que la dirección de la línea-de-visión desde la munición hasta el objetivo se mantiene constante con relación al cuadro inercial de referencia, es decir, en el caso plano $\lambda' = 0$ en la que λ es el ángulo entre la línea de visión munición – objetivo y una línea de referencia en el cuadro inercial; la ley de guía PN es entonces $a_{Mc} = k\lambda$, en la que a_{Mc} es el comando para aceleración lateral y k es una constante (ganancia); por lo tanto, la aceleración lateral aplicada a la munición es proporcional a la tasa de cambio con el tiempo del ángulo λ .

- 25 Muchos sistemas de guía modernos se basan en una clase alternativa de técnicas, conocida comúnmente como guía óptima. En la guía óptima, más que determinar el control a la vista de una ley geométrica, el control se determina con una vista a reducir al mínimo una función de coste. La función de coste es típicamente una función de la distancia errónea, es decir, la distancia en la que la munición errará su objetivo, y el esfuerzo de control, es decir, la cantidad de esfuerzo requerido para alcanzar el objetivo (es decir, la cantidad de combustible requerido). El problema de la guía implica también típicamente limitaciones, por ejemplo relacionadas con la dinámica de la munición. La solución del problema de la optimización, analíticamente o por métodos numéricos implementados por ordenador, proporciona el control óptimo, que reduce al mínimo la función de coste.

- 35 En situaciones de guía prácticas, normalmente no se conoce el estado de un objetivo y tiene que determinarse a través de mediciones. Estas mediciones se utilizan para determinar una distribución de probabilidades implicadas de la localización futura del objetivo, a la que el perseguidor debe ser guiado de una manera óptima. Cuando la localización del objetivo se puede describir utilizando una distribución de probabilidades Gaussiana, la guía es relativamente recta. Sin embargo, cuando la distribución del objetivo no se puede describir utilizando una distribución de probabilidades gaussiana, por ejemplo cuando la localización del objetivo está limitada a un número de localizaciones discretas posibles (por ejemplo, un número de rutas de carretera posible, que el objetivo puede estar tomando), el problema de la guía se vuelve más difícil.

- 40 La manera clásica de representar la distribución de probabilidades del objetivo cuando es no-Gaussiana consiste en utilizar un Filtro de Partículas (introducido por N. J. Gordon, D. J. Salmond, y A. F. M. Smith, en su publicación básica Novel approach to nonlinear/non-Gaussian Bayesian state estimation, IEE Proc. -F, vol 140, No 2, páginas 107-113, 1993). M. S. Arulampalam, S. Maskell, N. Gordon, y T. Clapp (in A tutorial on particle filters for non-linear/non-gaussian Bayesian tracking, IEE Trans. Signal processing, Vol. 50, Febrero 2002) proporcionan una guía didáctica introductoria sobre Filtrado de Partículas, y A. Doucet, N. de Freitas, y N. Gordon (editores, in Sequential Monte Carlo Methods in Practice. Springer-Verlag, 2001) dan una colección de informes que describen la teoría que sirve de base para el Filtrado de Partículas, junto con varias mejoras y aplicaciones del Filtrado de Partículas. El Filtrado de Partículas describe esencialmente la distribución futura del objetivo utilizando una muestra ponderada de trayectorias del objetivo a partir de la presente distribución del objetivo. Simplifica la implementación de la regla Bayesiana para actualizaciones de mediciones modificando justamente los pesos de las partículas y luego muestreando de nuevo después de cada medición. La población de trayectorias ponderadas resultantes del objetivo se utiliza para calcular aproximadamente un valor esperado de una función del estado del objetivo como una variable aleatoria. Esto se hace justamente aplicando la función a la muestra de la trayectoria del objetivo y luego formando una suma ponderada de los resultados utilizando los pesos del filtro de partículas. Aunque esto proporciona una manera de medir y predecir propiedades del objetivo, no aborda cómo guiar el perseguidor hacia el

objetivo.

Uno de los problemas principales en la Guía y Control es guiar un perseguidor hacia un objetivo que tiene genuinamente estadísticas no-Gaussianas, de manera que el algoritmo de guía proporciona el mejor resultado medio con respecto a la distancia errónea, la maniobra del perseguidor y los costes del estado del perseguidor, sujetos a limitaciones del estado del perseguidor. D. J. Salmond, N. O. Everett, y N J Gordon ("Target tracking and guidance using particles", en Proceedings of the American Control Conference, páginas 4387-4392, Arlington, VA, Junio 25-27 2001) han sido pioneros en esta área utilizando una ley de guía sencilla, con una forma fija y en un informe posterior (D Salmond y N. Gordon, "Particles and mixtures for tracking and guidance", en A. Doucet, N. de Freitas, y N. Gordon, editores, Sequential Monte Carlo Methods in Practice, páginas 518 - 532. Springer-Verlang, 2001) clasificaron varios de tipos de soluciones subóptimas de guía.

Un sistema de guía de misiles iterativo en tiempo real se describe en la patente US 5.435.503.

Sería ventajoso proporcionar un método y un aparato mejorados para guiar hacia un objetivo que tiene estadísticas no-Gaussianas.

Descripción de la invención

Un primer aspecto de la invención proporciona un método de guía de un perseguidor hacia un objetivo, comprendiendo el método:

(a) proporcionar una pluralidad de trayectorias de objetivos posibles, ponderadas para representar una distribución de probabilidades de las trayectorias de los objetivos;

(b) proporcionar una pluralidad de controles de guía candidatos, parametrizados por un parámetro de guía candidato;

(c) para cada uno de una pluralidad de valores de los parámetros de guía candidatos:

a. determinar una trayectoria proyectada del perseguidor, que resulta del control de guía candidato que corresponde al valor del parámetro de guía candidato;

b. utilizando la trayectoria proyectada del perseguidor desarrollada hasta ahora, determinar la siguiente aparición de una condición de terminación para la trayectoria del perseguidor relativa a una cualquiera de las trayectorias del objetivo para las que no ha aparecido todavía una condición de terminación;

c. ajustar la trayectoria proyectada del perseguidor, a continuación de esa aparición de la condición de terminación, para tener en cuenta esta trayectoria del objetivo;

d. repetir las etapas b y c hasta que hayan sido tenidas en cuenta las condiciones de terminación que corresponden a toda la pluralidad de trayectorias posibles de los objetivos; y

e. registrar un coste para el control de guía candidato sobre la base de la trayectoria proyectada del perseguidor y las distancias erróneas a la aparición de la condición de terminación para cada trayectoria del objetivo;

(d) generar una pluralidad revisada de valores de los parámetros de guía candidatos a la vista de los costes registrados de los controles de guía candidatos.

(e) repetir las etapas (c) y (d) una pluralidad de veces e identificar un control de guía óptimo sobre la base de los costes registrados;

(f) aplicar el control de guía óptimo sobre el vehículo perseguidor para alterar su trayectoria actual;

(g) obtener trayectorias posibles actualizadas de objetivos; y

(h) repetir las etapas (b) a (g) una pluralidad de veces.

La condición de terminación relativa a una trayectoria del objetivo puede ser el punto de máxima aproximación de la trayectoria proyectada del perseguidor con respecto a la trayectoria del objetivo.

El parámetro de guía candidato puede ser un parámetro Costate.

Las trayectorias del objetivo se pueden describir por estadísticas no-Gaussianas. Las trayectorias del objetivo pueden ser rutas posibles de un vehículo objetivo. Las rutas posibles pueden comprender un número de trayectorias discretas posibles, por ejemplo rutas de carretera. Las rutas de carretera son un ejemplo de trayectorias posibles del objetivo, donde la aparición siguiente de una condición de terminación para la trayectoria del perseguidor con relación a cada una de las trayectorias del objetivo es significativamente diferente.

Los nuevos controles de guías candidatos pueden ser generados utilizando un algoritmo de optimización. El algoritmo de optimización puede ser un algoritmo de geolocalización. El algoritmo de geolocalización puede ser un algoritmo de geolocalización maestro-esclavo. Puede ser que, en el algoritmo maestro-esclavo, si no se encuentran soluciones factibles, se incremento un peso de limitación; de manera similar, se puede incrementar un peso de limitación si existe demasiada holgura.

5 El método puede comprender re-direccionar una trayectoria proyectada atenuando una oscilación de alta frecuencia en la trayectoria proyectada.

10 El método puede comprender proporcionar una o más limitaciones de estado del perseguidor, de tal manera que cada coste registrado en la etapa (e) para el control de guía candidato es sometido a dicha(s) limitación(es) de estado del perseguidor. Las limitaciones de estado del perseguidor pueden tener en cuenta, por ejemplo, áreas de exclusión para el perseguidor.

Un segundo aspecto de la invención proporciona aparatos de procesamiento dispuestos para realizar las etapas de un método de acuerdo con el primer aspecto de la invención.

15 El aparato de procesamiento puede estar comprendido en el perseguidor que puede ser, por ejemplo, un vehículo. El vehículo puede ser un vehículo aéreo, por ejemplo un avión o un misil u otra munición guiada. Por lo tanto, un tercer aspecto de la invención es proporcionar un vehículo que comprende un aparato de acuerdo con el segundo aspecto de la invención. El vehículo puede incluir un sensor de corto alcance para adquirir el objetivo y seguirle el rumbo utilizando un dispositivo de conducción automática convencional, por ejemplo cuando el vehículo está a menos de 1 km, menos de 500 m o menos de 250 m desde el objetivo.

20 Alternativamente, el aparato de procesamiento puede estar separado del perseguidor, por ejemplo en una estación de radar de base en tierra.

Se apreciará evidentemente que las características descritas con relación a un aspecto de la presente invención se pueden incorporar en otros aspectos de la presente invención. Por ejemplo, el método de la invención puede incorporar una cualquiera de las características descritas con referencia al aparato de la invención y viceversa.

25 **Breve descripción de los dibujos**

A continuación se describirán formas de realización ejemplares solamente de forma ejemplar y con referencia a los dibujos que se acompañan, en los que:

La figura 1 es una instantánea de un fichero .avi que muestra la salida de un método de acuerdo con una forma de realización ejemplar de la invención, rotulada con comentarios.

30 Las figuras 2 a 7 son otras instantáneas del fichero .avi que muestran la salida del método del ejemplo para un primer objetivo ejemplar.

Las figuras 8 a 12 son otras instantáneas del fichero .avi que muestran la salida del método ejemplar para un segundo objetivo ejemplar; y

La figura 13 es un diagrama de flujo que muestra una forma de realización ejemplar del método de la invención.

35 **Descripción detallada**

En una forma de realización ejemplar de la invención, un método de guía de un vehículo de persecución hacia un objetivo tiene en cuenta el hecho de que diferentes localizaciones posibles del objetivo tienen diferentes tiempos de paso, y utiliza directamente la salida bruta del Filtro de Partículas. Aborda el caso en el que los resultados de las mediciones no están afectados por el estado del perseguidor (por ejemplo, donde las mediciones se realizan por un radar de vigilancia de terceros, más que por el perseguidor propiamente dicho – en el último caso, la calidad de la medición podría ser una función del alcance del objetivo).

40 En la descripción anterior, para una muestra dada de la trayectoria del objetivo del Filtro de Partículas, se muestra cómo se derivan ecuaciones diferenciales para la guía, y cómo están influenciadas por la salida del Filtro de Partículas. Se muestra que la ley de guía tiene Costates que saltan en los puntos en los que el perseguidor pasa el Punto de Máxima Aproximación (PONA) para cada muestra de la trayectoria del objetivo.

45 Un perseguidor está en una posición al menos aproximadamente conocida y sobre una cabecera /al menos aproximadamente) conocida. Recibe información con respecto a localizaciones posibles de un objetivo ¿Qué control de guía debería aplicarse al perseguidor para alterar su trayectoria y guiarlo de una manera óptima hacia su objetivo, dada la información recibida?. El método adoptado es proporcionar un conjunto de controles de guía candidatos y graduar cada uno de ellos asignándole un coste. La graduación se utiliza entonces para generar un nuevo conjunto de control de guía candidatos, de acuerdo con un algoritmo de optimización descrito en detalle a continuación.

Después de una pluralidad de iteraciones del algoritmo, el control de guía candidato con la mejor graduación es seleccionado y aplicado al perseguidor, por ejemplo aplicando controles de velocidad y/o direccionales apropiados para el perseguidor.

En primer lugar realizamos un cálculo ejemplar del coste esperado para un control de guía candidato.

- 5 Las localizaciones exactas presente y futuras del objetivo no son conocidas, pero se pueden representar como una distribución de probabilidades,, Supongamos que $y(t : \omega)$ es la variable aleatoria que representa el estado del objetivo como una función del tiempo. Consideramos esto como un conjunto de trayectorias de estado Ω con medida de la probabilidad dPr . Aunque el control de guía óptimo calculado por el método debe aplicarse en el corto plazo (es decir, una vez que el cálculo está completo), el método implica predecir la trayectoria futura del perseguidor para cada control de guía candidato, en el supuesto de que ese control de guía candidato esté adaptado para el corto plazo. Las consecuencias de aplicar un control de guía candidato pueden ser tales que se prevé que el perseguidor se mueva hacia y fuera del objetivo durante el acoplamiento.

En general, el coste para una instancia del objetivo es

$$J(\omega) = \phi(x, y(t, \omega)) \Big|_{t=t_p(\omega)} + \int_{t_0}^{t_p(\omega)} L(u, x, t) dt \quad (1)$$

- 15 en la que ϕ es el coste terminal que representa el coste de perder el objetivo, L es el coste integrado del perseguidor para la trayectoria del perseguidor en consideración, x es el estado actual del perseguidor, u es el control de guía candidato en consideración, y t_p es el tiempo terminal hasta el que se mide el coste. Este tiempo terminal es el "punto de máxima aproximación" (PONA) para la instancia del objetivo. Cada vez que el perseguidor pasa por un PONA local, pasa a través de un punto de inflexión dado por la condición

$$20 \quad \psi(x, y^{(i)}, \dot{y}^{(i)}) \Big|_{t_p(\omega)} = 0 \quad (2)$$

u es la entrada de control utilizada para guiar el perseguidor con estado x dado por la ecuación de limitación

$$\dot{x} = f(x, u, t) \quad (3)$$

- 25 Las formas particulares de las funciones ϕ , L , ψ y f pueden ser definidas por un escenario de persecución dado.

La estrategia adoptada consiste en seleccionar una ley de guía para reducir al mínimo el coste esperado sobre todas las trayectorias posibles del objetivo:

$$30 \quad E(u) = \int_{\Omega} J(\omega) dPr \quad (4)$$

sujeto a las limitaciones anteriores (notar la dependencia del comando de guía u). El coste es ponderado, por lo tanto, por la probabilidad dPr de trayectorias del objetivo Ω . En este ejemplo, no existe ninguna interacción en trayectorias.

- 35 Los filtros de partículas proporcionan una manera conveniente para representar $E(u)$ como una suma ponderada de contribuciones. Si suponemos que J es una función medible utilizando la medida dPr , entonces un filtro de partículas selecciona una secuencia de pesos y trayectorias $\{(w_i, \omega_i) \in R^+ \times \Omega | i \in N\}$, de tal manera que

$$40 \quad E(u) = \lim_{n \rightarrow \infty} \frac{\sum_{i=1}^n w_i J(\omega_i)}{n} \quad (5)$$

Si $J(\cdot)$ es una función que adopta el valor 1 constante, entonces a partir de la Ecuación (5) y la definición de la Ecuación (4) obtenemos

$$\lim_{n \rightarrow \infty} \frac{\sum_{i=1}^n w_i J(\omega_i)}{n} = 1 \quad (6)$$

- 45 puesto que dPr es una medida de probabilidad.

En la práctica, el coste general esperado $E(u)$ se aproxima sumando sobre un número finito N de trayectorias del objetivo para dar la aproximación

$$E(u) = \sum_{i=1}^N w_i J(\omega_i) \quad (7)$$

donde normalizamos los pesos para satisfacer

$$\sum_{i=1}^N w_i = 1 \quad (8)$$

para asegurar que el resultado se comporta como una distribución de probabilidad. Tal aproximación da, como una aproximación de la Ecuación (4), utilizando la Ecuación (1)

$$E(u) = \sum_{i=1}^N w_i \phi(x, y^{(i)}) + \int_{t_0}^{t_f} n(t) L(u, x, t) dt \quad (9)$$

en la que

$$t_i = t_p(\omega_i), y^{(i)} = y(\omega_i), t_f = \max(t_1, \dots, t_N) \quad (10)$$

$$h(t, i) = \begin{cases} 1 & \text{si } t \leq t_i \\ 0 & \text{o en otro modo} \end{cases} \quad (11)$$

$$n(t) = \sum_{i=1}^N w_i h(t, i) \quad (12)$$

Por lo tanto, el coste esperado para cada control de guía candidato u incluye funciones de etapa h que provocan que el coste del perseguidor para la trayectoria (es decir, el integrando en la Ecuación (9)) salte cada vez que se pasa el PONA para cada una de las N trayectorias del objetivo en consideración; es decir, que una vez que se pasa el PONA, en el instante t_i , para una trayectoria posible del objetivo en la integración en la Ecuación (9), esa trayectoria del objetivo no contribuye ya al coste del resto de la integración (es decir, la integración desde t_i a t_f , siendo t_f el PONA de la trayectoria final del objetivo a pasar).

Para resolver (9), utilizamos el método bien conocido de adjuntar los multiplicadores de Lagrange, para dar una nueva función del coste J_A :

$$J_A = \sum_{i=1}^N w_i \Phi(x, y^{(i)}) + \int_{t_0}^{\infty} \{ H(u, x, t) - n(t) \lambda^T(t) \dot{x} \} dt \quad (13)$$

$$H = n(t) \{ L(u, x, t) + \lambda^T f \} \quad (14)$$

$$\Phi^{(i)} = \Phi(x, y^{(i)}) = \phi(x, y^{(i)}) + v_i \psi(x, y^{(i)}, \dot{y}^{(i)}) \quad (15)$$

H es el Hamiltoniano ponderado, y la función λ^T es la sensibilidad de estado Costate y la función v_i es la sensibilidad PONA Costate.

La integración por partes da:

$$J_A = \sum_{i=1}^N w_i \Phi(x, y^{(i)}) + n(t_0) \lambda^T(t_0) x(t_0) - n(t_\infty) \lambda^T(t_\infty) x(t_\infty) + \int_{t_0}^{\infty} \left\{ H(u, x, t) + \frac{d(n(t) \lambda^T)}{dt} x \right\} dt \quad (16)$$

Ahora consideramos la variación de J_A debido a la variación de u con tiempo fijo t_0 y ninguna variación de la condición inicial. Teniendo en cuenta que $\lambda(\infty) = 0$ debido a que no existe ninguna influencia más allá del tiempo t_f , obtenemos

$$\delta J_A = \sum_{i=1}^N w_i \left\{ \frac{\partial \Phi^{(i)}}{\partial x} [\delta x + \dot{x} \delta t_i] + \frac{\partial \Phi^{(i)}}{\partial t} \delta t_i \right\} + Q(t_i) \delta t_i + \int_{t_0}^{t_f} \left\{ \left[\frac{\partial H}{\partial x} + n \lambda^T + \dot{n} \lambda^T \right] \delta x + \frac{\partial H}{\partial u} \delta u \right\} dt \quad (17)$$

donde

$$Q(t_i) = n(t_i^-)L(u(t_i^-), x(t_i^-), t_i^-) - n(t_i^+)L(u(t_i^+), x(t_i^+), t_i^+) \quad (18)$$

es el salto en el integrando original en t_i , cuando $\dot{x} = f(u, x, t)$. Reorganizando la Ecuación (17) da

$$\begin{aligned} \delta J_A = & \sum_{i=1}^N w_i \left\{ \frac{d\Phi^{(i)}}{dt} \delta t_i \right\} \Big|_{t_i} + Q(t_i) \delta t_i \\ & + \int_{t_0}^{t_f} \left\{ \left[\sum_{i=1}^N w_i \left(\frac{\partial \Phi^{(i)}}{\partial x} - (\lambda^T + 0.5 \delta \lambda^{(i)}) \right) \Delta(t_i) + \left(\frac{\partial H}{\partial x} + n \lambda^T \right) \right] \delta x + \frac{\partial H}{\partial u} \delta u \right\} dt \end{aligned}$$

5

donde $\Delta(s)$ es la función Dirac delta con la propiedad $\int g(t) \Delta(s) dt = g(s)$ y

$$\frac{d\Phi^{(i)}}{dt} = \frac{\partial \Phi^{(i)}}{\partial x} \dot{x} + \frac{\partial \Phi^{(i)}}{\partial t} \quad (19)$$

10 Mediante la selección adecuada de las funciones Costate λ y v_i , podemos establecer

$$w_i \frac{d\Phi^{(i)}}{dt} \Big|_{t_i} = -Q(t_i) \quad (20)$$

$$\lambda^T = \sum_{i=1}^N \frac{w_i}{n(t)} \left\{ -\frac{\partial \Phi^{(i)}}{\partial x} + (\lambda^T + 0.5 \delta \lambda^{(i)}) \right\} \Delta(t_i) - \frac{\partial L}{\partial x} - \lambda^T \frac{\partial f}{\partial x} ; \lambda(t_f^+) = 0 \quad (21)$$

15 que da

$$\delta J_A = \int_{t_0}^{t_f} \frac{\partial H}{\partial u} \delta u dt = 0 \quad (22)$$

Esto está cerca de cero para todo δu pequeño posible dando un punto de inflexión cuando

$$\frac{\partial H}{\partial u} = 0 \quad (23)$$

20

La expansión de la Ecuación (23) ligeramente da

$$\frac{\partial L}{\partial u} + \lambda^T \frac{\partial f}{\partial u} = 0 \quad (24)$$

25 que da la ley de control óptima una vez que las funciones de influencia Costate λ han sido evaluadas utilizando la Ecuación (21).

La Ecuación (24) está próxima a la solución óptima clásica de sistemas continuos, pero existe un efecto añadido debido a la dispersión de la influencia de la posición desconocida del PONA del objetivo: la solución tiene un salto pequeño en el co-state λ , en cada tiempo PONA de la partícula del objetivo, de la cantidad $\delta \lambda^{(i)}$. La Ecuación (21) da

30

$$(n(t_i^-) - 0.5 w_i) \delta \lambda^{(i)} = w_i \left\{ -\frac{\partial \Phi^{(i)}}{\partial x} + \lambda^T + 0.5 \delta \lambda^{(i)} \right\} \Big|_{t=(t_i^-)} \quad (25)$$

(El factor de 0,5 es debido a la integración de una función delta multiplicada por una etapa en el delta. Por ejemplo, supongamos que $U(t)$ es la etapa unitaria en $t = 0$, entonces la función delta es

35

$$\Delta(t) = \frac{dU(t)}{dt}$$

y tenemos

$$0.5 \Delta(t) = 0.5 \frac{dU(t)}{dt} = 0.5 \frac{dU^2(t)}{dt} = U(t) \frac{dU(t)}{dt} = U(t) \Delta(t);$$

es decir, que la ecuación debe multiplicarse por $n(t)$ antes de que se igualen los lados en t_i .)

Dando:

$$\delta\lambda^{(i)} = \frac{w_i}{(n(t_i^-) - w_i)} \left\{ -\frac{\partial\Phi^{(i)}}{\partial x} + \lambda^T + \delta\lambda^{(i)} \right\} \Bigg|_{t=t_i^-} \quad (26)$$

integrando al mismo tiempo la solución para λ (observar que el valor de los términos depende también de λ y de esta manera debe evaluarse antes del salto).

Por lo tanto, se puede calcular una solución de guía óptima u por integración numérica de la Ecuación 24, teniendo en cuenta los saltos $\delta\lambda^{(i)}$ en la función Costate λ que aparece en cada trayectoria del objetivo PONA.

Ahora consideramos una aplicación específica del método ejemplar, para el caso ilustrativo de una persecuidor a velocidad constante en el plano-xy. Esto es útil para la planificación dinámica de la misión de un persecuidor aerotransportado contra objetivos móviles en tierra. Éste es un caso de ensayo sencillo para el algoritmo de guía e ilustra cómo aplicar las ecuaciones generales de guía. Las ecuaciones derivadas de guía se pueden utilizar para planificación dinámica de la misión, donde suponemos que el persecuidor viaja a una velocidad de crucero constante antes de acoplarse con el objetivo. Naturalmente, la dinámica se puede extender para tratar con un comportamiento dinámico más representativo, por ejemplo si existe una necesidad de látex excesivo, con arrastre inducido resultante. No obstante, este caso simple puede ser implementado para ejecución en tiempo real o en tiempo casi real en un ordenador personal e ilustra muchas características utilizadas en la implementación de una ley de guía.

Una vez que se conoce cómo resolver los saltos Costate en cada PONA, se pueden integrar soluciones de guía sobre la base de un State y Costate inicial (esta soluciones se llaman barridos hacia delante). Las soluciones de guía generadas de esta manera son soluciones candidatas parametrizadas por el Costate inicial, que deja el problema de hallar el Costate inicial óptimo (dando el control de guía óptimo).

El vector State para el persecuidor es $x = (x_m, y_m, \gamma_m)$ con ecuaciones de movimiento

$$\dot{x}_m = V_m \cos \gamma_m \quad (27)$$

$$\dot{y}_m = V_m \sin \gamma_m \quad (28)$$

$$\dot{\gamma}_m = u \quad (29)$$

x_m, y_m) es la localización, v_m es la velocidad constante, y γ_m es la dirección de vuelo del persecuidor.

La finalidad principal es que el persecuidor vuele sobre un objetivo sobre el suelo, evitando al mismo tiempo varios obstáculos o zonas peligrosas en el plano-x-y. Esto se puede utilizar para dar un rango de escenarios con dificultad creciente.

Este ejemplo es suficientemente difícil para no tener una solución manejable de forma cerrada, incluso en el caso más simple de volar sobre un objetivo fijo en tiempo abierta, y tiene el potencial de tener barridos hacia delante que tienen muchas soluciones oscilatorias que están lejos de ser óptimas para el presente caso. Para un objetivo sencillo $\omega_i \in \Omega$ se supone que la función de coste tiene la forma

$$J(\omega_i) = 0.5g(m^2(\omega_i)) + \int_{t_0}^{t_f} B(x, t) + 0.5u^2 dt \quad (30)$$

La función de coste ha sido normalizada dividiendo con una constante para dar la ganancia unitaria de coste debido a la aplicación del control u . $m(\omega_i)$ es la distancia mínima del objetivo antes del final del vuelo o la distancia proyectada errónea. No obstante, este coste debería estar saturado para ser más realista y dar mejores resultados, de manera que utilizamos la función de coste más general $0.5g(m^2(\omega_i))$ de distancia errónea, donde g se satura. B representa la resistencia de las zonas peligrosas (o trayectorias preferidas, si es negativa). Supongamos que $z_M = (x_m, y_m)$ es la posición del persecuidor y $z_T^{(i)}$ es la posición de la partícula del objetivo i . Entonces la parte "errónea" de la función de coste se da como la distancia ponderada al cuadrado en PONA

$$\phi^{(i)} = \phi(x, y^{(i)}) = 0.5g \left((z_M - z_T^{(i)})^T (z_M - z_T^{(i)}) \right) \Bigg|_{t_i} \quad (31)$$

y la condición PONA se da por

$$\psi^{(i)} = \psi(x, y^{(i)}, \dot{y}^{(i)}) = \left(z_M - z_T^{(i)} \right)^T \left(\dot{z}_M - \dot{z}_T^{(i)} \right) \Big|_{t_i} = 0 \quad (32)$$

para cada partícula. Ahora esto tiene la propiedad siguiente

$$\frac{d\phi^{(i)}}{dt} = \frac{\partial g}{\partial m^2} \left(z_M - z_T^{(i)} \right) \dot{z}_M - \frac{\partial g}{\partial m^2} \left(z_M - z_T^{(i)} \right) \dot{z}_T \quad (33)$$

$$= \frac{\partial g}{\partial m^2} \left(z_M - z_T^{(i)} \right)^T \left(\dot{z}_M - \dot{z}_T \right) \quad (34)$$

de manera que

$$\left. \frac{d\phi^{(i)}}{dt} \right|_{t_i} = 0 \quad (35)$$

como se espera en PONA. Ahora

$$\frac{d\psi^{(i)}}{dt} = V^{(i)} + m^{(i)}u - (z_M - z_T^{(i)})\ddot{z}_T \quad (36)$$

donde

$$m^{(i)} = (z_M - z_T^{(i)})^T (-\sin \gamma_m, \cos \gamma_m) V_m \quad (37)$$

$$V^{(i)} = (\dot{z}_M - \dot{z}_T^{(i)})^T (\dot{z}_M - \dot{z}_T) \quad (38)$$

Utilizando la definición de la Ecuación (15) junto con las Ecuaciones (31, 32), obtenemos

$$\frac{\partial \Phi^{(i)}}{\partial z_M} = \left(\frac{\partial g}{\partial m^2} (z_M - z_T^{(i)}) + v^{(i)} (\dot{z}_M - \dot{z}_T^{(i)}) \right)^T \Big|_{t_i} \quad (39)$$

$$\frac{\partial \Phi^{(i)}}{\partial \gamma_m} = v^{(i)} (z_M - z_T^{(i)})^T (-\sin \gamma_m, \cos \gamma_m) V_m = v^{(i)} m^{(i)} \quad (40)$$

Utilizando estas identidades, la actualización incremental como una función de v_i se puede calcular ahora a partir de la Ecuación (26):

$$\left[\delta \lambda_x^{(i)}, \delta \lambda_y^{(i)} \right] = \frac{w_i}{n(+t_i)} \left\{ -\frac{\partial g}{\partial m^2} (z_M - z_T^{(i)}) - v^{(i)} (\dot{z}_M - \dot{z}_T^{(i)}) + [\lambda_x, \lambda_y] \right\} \quad (41)$$

$$\delta \lambda_\gamma^{(i)} = \frac{\omega_i}{n(+t_i)} \left\{ -v^{(i)} m^{(i)} + \lambda_\gamma^{(i)} \right\} \quad (42)$$

Sustituyendo la ecuación de movimiento (27) a ecuación (29) en la Ecuación (24) y la Ecuación (30) da la ley de control clásico en términos del co-state:

$$u = -\lambda_\gamma \quad (43)$$

Por lo tanto, las soluciones de guía candidatas son parametrizadas por la función co-state, como se ha indicado anteriormente. Además, a medida que el perseguidor para el PONA de cada trayectoria del objetivo, las etapas en el Costate corresponden a la alteración del control de guía; por lo tanto, la trayectoria proyectada para la solución de guía inicial es alterada una vez que se pasa cada PONA, para tener en cuenta la trayectoria posible del objetivo que ha sido pasada.

La etapa siguiente es calcular $V^{(i)}$ en términos de Costates $\lambda = (\lambda_x, \lambda_y, \lambda_z)$ y estados del perseguido, de manera que la dinámica Costate dada por la Ecuación (21) puede ser integrada (utilizando un barrido hacia delante). Este proceso de integración de la trayectoria Costate corresponde, en virtud de la Ecuación (43), a determinar la trayectoria proyectada para el control de guía candidato.

Específicamente, a partir de la Ecuación (20) y la condición ortogonal de la Ecuación (35), obtenemos

$$V^{(i)} = - \frac{Q(t_i)}{w_i \frac{d\psi^{(i)}}{dt}} \quad (44)$$

No obstante, $Q(t_i)$ depende del salto $\delta_{ij}u = u(t_i^-) - u(t_i^+)$ que, a su vez, depende de $V^{(i)}$. De hecho, utilizando la ley de control de la Ecuación (43), la definición de L dada en la Ecuación (30) y la definición de la Ecuación (18), la fundición cada vez en términos de $\delta\lambda$, tenemos:

$$Q(t_i) = +w_i \{B + 0.5\lambda_y^2\} - n(t_i^+) \{0.5\delta\lambda_y^{(i)} + \lambda_y\} \delta\lambda_y^{(i)} \quad (45)$$

La Ecuación (45) es casi lineal, suponiendo que los saltos en t_i son comparativamente pequeños. Volviendo a la Ecuación (44) y llevando el denominador de retorno sobre la izquierda, obtenemos sustituyendo la Ecuación (45)

$$V^{(i)} w_i \frac{d\psi^{(i)}}{dt} = -w_i \{B + 0.5\lambda_y^2\} + n(t_i^+) \{0.5\delta\lambda_y^{(i)} + \lambda_y\} \delta\lambda_y^{(i)} \quad (46)$$

Ahora sustituimos la Ecuación (42) para dar

$$V^{(i)} w_i \left\{ \frac{d\psi^{(i)}}{dt} + m\lambda_y \right\} = w_i \left\{ -B + 0.5\lambda_y^2 \right\} + 0.5n(t_i^+) [\delta\lambda_y^{(i)}]^2 \quad (47)$$

Sustituyendo desde la Ecuación (36) y disponiendo, obtenemos

$$V^{(i)} = D^{-1} \left(-B + 0.5\lambda_y^2 + 0.5 \frac{n(t_i^+)}{w_i} [\delta\lambda_y^{(i)}]^2 \right) \quad (48)$$

$$D = V^{(i)} + m^{(i)}u - (z_M - z_T^{(i)}) \ddot{z}_T + m^{(i)}\lambda_y \quad (49)$$

$$= V^{(i)} - (z_M - z_T^{(i)}) \ddot{z}_T$$

El término de segundo orden $[\delta\lambda_y^{(i)}]^2$ es todavía una función de $V^{(i)}$ que podría tenerse en cuenta mediante sustitución en la Ecuación (42); no obstante, la implementación reconoce que éste es un término de segundo orden pequeño,

ya que se utiliza un valor aproximado por el primero utilizando la Ecuación (48) con $\delta\lambda_y^{(i)} = 0$, y entonces se utiliza

esta primera aproximación para $V^{(i)}$ en la Ecuación (42) para dar una mejor aproximación para $\delta\lambda_y^{(i)}$,

que se utiliza entonces en la Ecuación (48) para dar la aproximación final a $V^{(i)}$. Ésta se utiliza entonces para dar $\delta\lambda$ a partir de las Ecuaciones (41) y (42).

Siguiendo este procedimiento y utilizando un valor inicial estimado aproximado para el Costate, el algoritmo barre hacia delante integrando la Ecuación (21) hasta que se detecta un PONA para un filtro de partículas (es decir, la trayectoria más próxima del objetivo). En esa etapa, se calcula $V^{(i)}$ y se calculan los saltos en el Costate $\delta\lambda$ de la manera indicada en esta sección. Este proceso se continúa hasta que todas las partículas en el filtro de partículas son tenidas en consideración (es decir, se han pasado todos los PONAs de todos los objetivos).

Lo siguiente da un método general para uso para calcular el $\delta\lambda^{(i)}$ en un PONA. En el caso general, la condición

$$\psi(x, y, \dot{y}^{(i)}) \Big|_{t_p(\omega)} = 0$$

Es el punto de máxima aproximación en el sentido de que la función de coste φ alcanza un mínimo (máximo) local,

de manera que su tasa de cambio es cero como una función de tiempo, por lo tanto

$$\left. \frac{d\phi^{(i)}}{dt} \right|_{t_i} = 0$$

en PONA.

5

Por consiguiente, las ecuaciones (20) y (15) nos dan que

$$v^{(i)} = - \frac{Q(t_i)}{w_i \frac{d\psi^{(i)}}{dt}}$$

10 La expresión a la derecha arriba es una función conocida del estado de guía x y el tiempo en el denominador, pero el numerador es una función del control u y su salto así como el estado x y el tiempo en PONA. El tiempo y el estado son continuos en un PONA, pero u no. A partir de la ecuación (24) mediante sustitución de los valores conocidos de L y F a partir de las Ecuaciones (1) y (3) obtenemos u como una función de λ así como los valores conocidos de estado x y el tiempo en PONA. Mediante sustitución obtenemos $v^{(i)}$ como una función del $\delta\lambda^{(i)}$ desconocido, luego
15 mediante sustitución obtenemos a partir de la Ecuación (15)

$$\left. \frac{\partial \Phi^{(i)}}{\partial x} \right|_{t=t_i-}$$

como una función de $\delta\lambda^{(i)}$. Sustituyendo esto en la Ecuación (26) da una relación derivable

20

$$\delta\lambda^{(i)} = F_i(\delta\lambda^{(i)}) \quad (A1)$$

En la práctica, las funciones de costes se seleccionarán para que $F_i()$ sea una función que se puede derivar como una expresión algebraica de estado y tiempo. No obstante, esto no excluye su evaluación numérica. La solución a esta ecuación (A1) dará entonces el salto a los Costates. Esto se puede resolver por un método numérico general, tal como el método de Newton-Raphson (publicado, por ejemplo, por Cambridge University Press 1988 como "Numerical Recipes in C", Sección 9.3 por William H. Press y col.). Alternativamente, la ecuación se puede aproximar a menudo por una ecuación lineal para dar una solución inicial $\delta\lambda^{(i)}_n$ y aplicando entonces $\delta\lambda^{(i)}_{n+1} = F_i(\delta\lambda^{(i)}_n)$ para obtener una mejor solución $\delta\lambda^{(i)}_{n+1}$. Esto convergerá en una solución si $F_i()$ es una contracción próxima a la
25 solución. En la práctica, éste es el caso y se puede obtener una solución razonable con una iteración simple. El operador incluirá, naturalmente, un código para verificar esto contemplando el cambio en la solución con cada sustitución. Si la convergencia no es aparente, entonces se puede utilizar siempre el método de Newton-Raphson más expresivo.

35 El tamaño del salto se reduce con el número de trayectorias candidatas del objetivo, que se puede incrementar si el método simple no converge rápidamente incrementando el tamaño de la muestra del Filtro de Partículas. En este sentido, los saltos son un artefacto de la aproximación del Filtro de Partículas.

40 El método descrito hasta ahora proporciona un método de determinación para un control de guía candidato dado una trayectoria proyectada que tiene en cuenta el PONA de cada trayectoria del objetivo. Permite también registrar un coste para cada control de guía candidato (por ejemplo, utilizando la Ecuación 9), estando basado el coste sobre la trayectoria proyectada y las distancias erróneas en el PONA de cada trayectoria del objetivo. La siguiente etapa es determinar el control de guía óptimo a partir del espacio de controles de guía posibles, a la vista de los costes calculados.

45

El problema de la optimización tiene muchos mínimos locales y de esta manera la subida de pendientes hasta una solución no es robusta. No obstante, se puede definir un área de investigación para buscar una solución, y se ha identificado un algoritmo de búsqueda aleatorio que tiene una buena cobertura de búsqueda y converge con un mínimo global en el área de búsqueda con alta probabilidad. Se utiliza un optimizador de geolocalización que investiga varias localizaciones de una vez, descrito por J Kennedy y R Eberhart ("Particle swarm optimization", en Proceedings of the IEEE International Conference on Neural Networks (Perth, Australia), volumen IV, páginas 1941 - 1948, Piscataway, NJ, 1995; IEEE Service Centre) junto con una extensión basada en el algoritmo "Master-Slave" descrito por Bo Yang, Yunping Chen, Zunlian Zhao, y Qiye Han ("A master-slave particle swarm optimization algorithm for solving constrained optimization problems", en Proceedings of the 6th World Congress on Intelligent Control and Automation, Dalian, China, Junio 2006) que encuentra de forma adaptable ponderaciones de
50
55

costes de limitaciones para una solución de optimización sujeta a limitaciones de estado del perseguidor. Esto se utiliza para tener en cuenta áreas de exclusión para el perseguidor en la planificación dinámica de la misión, como se describe más adelante.

En optimización de geolocalización, las soluciones candidatas son representadas por partículas de geolocalización, que son puntos particulares en el espacio de la solución del problema de interés (es decir, puntos en un espacio N-dimensional, con co-ordenadas dadas por N parámetros que juntos caracterizan la solución). Cada partícula tiene un vector de velocidad, que indica cómo cambiará su posición en el espacio de la solución en la siguiente iteración. Por lo tanto, las partículas candidatas de la solución “vuelan” a través del espacio de la solución de iteración a iteración. La dirección del vuelo se determina por dos factores: la localización previa óptima de la partícula, y la localización previa óptima entre todas las partículas; es el último factor es que puede dar como resultado el comportamiento de “geolocalización”, a medida que las partículas avanzan hacia la solución óptima (en términos del coste calculado). La efectividad del algoritmo se puede mejorar sustituyendo periódicamente nuevas soluciones en lugar de soluciones de mala ejecución.

El algoritmo de geolocalización de optimización original desarrollado por Kennedy y Eberhart ha sido modificado para dar el algoritmo estándar como se indica a continuación, donde tenemos una función de coste $f(x)$ de un vector de parámetro x que deseamos reducir al mínimo.

Por lo tanto, la optimización de geolocalización comienza seleccionando de forma aleatoria parámetros de partículas de geolocalización candidatas, $x^{[j]}$ para partículas $j = 1 \dots N_s$. Típicamente $N_s = 40$. Cada partícula mantiene un registro de su mejor parámetro de puntuación personal $p^{[j]}$ hasta ahora y la velocidad actualizada corriente $v^{[j]}$. Inicialmente, las velocidades actualizadas se ponen a cero. Supongamos que g es el mejor parámetro de puntuación global corriente. Se produce una nueva generación de partículas de geolocalización utilizando la regla de actualización:

$$v^{[j]} \rightarrow \text{Limit}(w^{[j]} \cdot v^{[j]} + K_1 \{ \text{aleat}_1^{[j]}(p^{[j]} - x^{[j]}) + \text{aleat}_2^{[j]}(g - x^{[j]}) \}) \quad (51)$$

$$x^{[j]} \rightarrow v^{[j]} + x^{[j]} \quad (52)$$

seguido por una actualización del mejor parámetro personal $p^{[j]}$ y el mejor parámetro global g . $\text{aleat}_1^{[j]}$ y $\text{aleat}_2^{[j]}$.

son vectores de números aleatorios con componentes distribuidos de una manera uniforme en el intervalo [0, 1]. Estos vectores aleatorios son multiplicados componente a componente por los vectores en la expresión. K_1 es una constante de sincronización normalmente fijada en 2, de manera que la actualización coloca la siguiente estimación aproximada alrededor del área del óptimo personal y el óptimo global cuando la velocidad previa es pequeña. $w^{[j]}$ se refiere como un término de inercia y se incluye para combatir la tendencia de la geolocalización a colapso prematuro en un punto individual. En una geolocalización se necesita dejar que algunos miembros se muevan con inercia pequeña para acelerar la convergencia, mientras otros miembros de la geolocalización retienen inercias grandes para motivarlos a explorar regiones fuera del mejor caso de puntuación corriente e incrementar la opción de hallar soluciones mejoradas. Para hacer esto, se selecciona $w^{[j]}$ de forma aleatoria para cada partícula en cada actualización a partir de la distribución uniforme en el intervalo [0,5 , 1,5]. La función Limit() limita la velocidad para asegurar que la búsqueda no recarga cambios de actualización grandes que provocan que las partículas afectadas omitan demasiados casos de puntuación mejorada. De hecho, este límite controla la dispersión de búsqueda alrededor del mínimo global para la distribución dada de $w^{[j]}$.

Esta geolocalización de optimización estándar no proporciona ninguna capacidad para incluir directamente una limitación y la limitación es aceptada a menudo aplicando un coste alto para la violación de la limitación. En lugar de esto, el algoritmo utilizado en esta forma de realización ejemplar utiliza el algoritmo Master Slave descrito ahora.

Las limitaciones son representadas por funciones del vector de parámetro $c_k(x)$ con $k = 1 \dots N_c$ y el conjunto factible se da por

$$F = \{x \mid c_k(x) \leq 0 \forall k = 1 \dots N_c\}$$

Para incorporar limitaciones en una construcción de la función de coste, deben determinarse una función de limitación auxiliar

$$d_k(x) = \begin{cases} 0 & \text{si } c_k(x) \leq 0 \\ c_k(x) & \text{o en otro modo} \end{cases} \quad (54)$$

y una pena de coste aumentada

$$\Theta(x) = f(x) + \sum_k \mu_k d_k(x) \quad (55)$$

5 donde $\mu_k > 0$ son ponderaciones de pena de limitación positivas a determinar. Hay que indicar que para un punto factible $\Theta(x) = f(x)$ y μ_k y μ_k se pueden seleccionar en principio para forzar que cualquier mínimo global de $\Theta(x)$ esté en el conjunto factible. La idea del algoritmo Maestro Slave utilizada por Yang y col. no es mejor que inducir a la geolocalización a contemplar bordes de limitación para soluciones candidatas al problema de optimización de limitaciones. El algoritmo Master Slave se utiliza para hallar un coste mínimo de $f(x)$ sujeto a la limitación $x \in F$.

10 El algoritmo Master Slave divide la geolocalización igualmente en una geolocalización maestra M y una geolocalización Esclava S. Las partículas candidatas de la solución en la geolocalización maestra exploran las regiones factibles del espacio de solución; las partículas candidatas de la solución en la geolocalización esclava exploran las regiones inviables del espacio de la solución. Las partículas de la solución para cada geolocalización pueden cambiar el tipo, el maestro se vuelve en el esclavo y viceversa, si su trayectoria de vuelo las toma a través de un borde de limitación, que permite a la geolocalización como un conjunto dispersarse en regiones que en otro caso (es decir, si solamente existiera la geolocalización maestra) estarían cerradas para él por áreas de limitación de "exclusión".

20 Por lo tanto, la geolocalización maestra tiene una relación de orden $<_M$ que favorece las soluciones factibles y el coste bajo (para una pareja de parámetros maestros (x, y) $x <_M y$ significa que x tiene mejor puntuación que y). La relación se define como:

$$x <_M y = (x \in F \wedge y \in F \wedge f(x) < f(y)) \vee (x \in F \wedge y \notin F) \vee (x \notin F \wedge y \notin F \wedge \Theta(x) < \Theta(y)) \quad (56)$$

25 donde $\wedge$ es el predicado y operador, $\vee$ es el predicado u operador y $\neg$ utilizado a continuación es el predicado *no* operador. De manera similar, las geolocalizaciones esclavas tienen una relación de orden $<_S$ que favorece las soluciones inviables y el coste aumentado pequeño. (Para una pareja de parámetros esclavos (x, y) $x <_S y$ significa que x tiene mejor puntuación que y). La relación se define como:

$$30 \quad x <_S y = (x \in F \wedge y \in F \wedge f(x) < f(y)) \vee (x \notin F \wedge y \in F) \vee (x \notin F \wedge y \notin F \wedge \Theta(x) < \Theta(y))$$

Si un parámetro x tiene componentes x_i , entonces se aplica $dist(x) = \sum_i |x_i|$; esto se utilizará para medir la distancia entre dos parámetros x , y como $dist(x - y)$.

35 La mitad de la geolocalización maestra consta de miembros que se llaman ML que son candidatos para actuar como guías para la geolocalización maestra y de manera similar la mitad de los miembros de la geolocalización se llaman SL y son candidatos para actuar como guías para geolocalización esclava. La idea de adoptar una guía distinta que el óptimo global se debe a que la geolocalización maestra y la geolocalización esclava tienen propósitos diferentes; además, teniendo un número grande de guías, varias soluciones competitivas candidatas locales se pueden explorar mejor evitando la adopción prematura de un óptimo local que no es óptimo. La idea básica del algoritmo es que cada miembro de geolocalización $i \in M \cup S$ mantiene un parámetro óptimo personal $p^{[i]}$, un parámetro de búsqueda corriente $x^{[i]}$ y una velocidad $v^{[i]}$. Para $i, j \in M$, definen las relaciones $i <_M j = p^{[i]} <_M p^{[j]}$ $i \leq_M j = \neg(j <_M i)$. Para $i, j \in S$ definen las relaciones $i <_S j = p^{[i]} <_S p^{[j]}$ $i \leq_S j = \neg(j <_S i)$.

45 Al inicio, $\mu_k = 1$, $k = 1 \dots N_c$ y $v^{[i]} = 0$, $j \in M \cup S$ luego el algoritmo ejemplar se itera de la siguiente manera:

1. Actualizar los valores de $\Theta(p^{[i]})$, $j \in M \cup S$

50 2. Para los esclavos, clasificar utilizando la relación $<_M$ y utilizar la mitad superior de la puntuación con el SL actual. (Esto ordena también el conjunto de guías de esclavos actuales, de manera que se puede hallar la peor clasificación).

3. Ahora procesar los maestros $j \in M$ como se indica a continuación:

55 (a) Hallar el $i \in ML$ de tal manera que $dist(p^{[i]} - p^{[j]}) = \min_{k \in ML} (dist(p^{[i]} - p^{[k]}))$
 (b) Actualizar el parámetro de búsqueda de una manera similar al algoritmo de optimización de

geolocalización estándar:

$$v^{[j]} \rightarrow Limit(w^{[j]}, v^{[j]} + K_1 \left\{ \text{aleat}_1^{[j]}(p^{[j]} - x^{[j]}) + \text{aleat}_2^{[j]}(p^{[i]} - x^{[j]}) \right\}) \quad (58)$$

$$x^{[j]} \rightarrow v^{[j]} + x^{[j]} \quad (59)$$

5 (c) Evaluar el coste asociado $\text{cost } \Theta(x^{[j]})$.

(d) Si $x^{[j]} \in F$ y $x^{[j]} <_M p^{[j]}$ fijar $p^{[j]} \rightarrow x^{[j]}$

10 (e) Si $x^{[j]} \notin F$ entonces sucede una cosa interesante. Supongamos que $w \in SL$ es la guía esclava de peor puntuación en el sentido de que $w <_S k$ nunca es verdad para $k \in S$, entonces sustituimos efectivamente w por j en el sentido siguiente: $p^{[w]} \rightarrow x^{[j]} x^{[w]} \rightarrow x^{[j]} v^{[w]} \rightarrow v^{[j]}$. Esto hace que j cruce el límite de factibilidad para convertirse en una guía esclava generada inviable, mientras permanece todavía como una guía maestra con un óptimo personal bueno. La idea es que esta guía esclava nueva estará muy probablemente cerca del límite de factibilidad y guiará a otros esclavos de retorno para producir maestros de buena puntuación que son factibles. La ordenación $<_S$ asegura que los esclavos inviables con costo Θ mínimo estén con preferencia en el grupo de guías esclavas. Después de modificar w , las esclavas se reordenan utilizando $<_S$ y la primera mitad de la población esclava se marca como guías esclavas.

20 4. Una vez que todas las maestras han sido procesadas, las esclavas son procesadas a su vez como sigue para cada $j \in S$:

(a) En primer lugar asegurar que las guías esclavas son la mejor mitad de la población esclava utilizando la relación $<_S$.

(b) Hallar el $i \in SL$ de tal manera que $\text{dist}(p^{[j]} - p^{[i]}) = \min_{k \in SL} (\text{dist}(p^{[j]} - p^{[k]}))$

25 (c) Actualizar el parámetro de búsqueda de una manera similar al algoritmo de optimización de geolocalización

$$v^{[j]} \rightarrow Limit(w^{[j]}, v^{[j]} + K_1 \left\{ \text{aleat}_1^{[j]}(p^{[j]} - x^{[j]}) + \text{aleat}_2^{[j]}(p^{[i]} - x^{[j]}) \right\}) \quad (60)$$

$$x^{[j]} \rightarrow v^{[j]} + x^{[j]} \quad (61)$$

30 (d) Evaluar el coste asociado $\Theta(x^{[j]})$.

(e) Si $x^{[j]} \notin F$ y $x^{[j]} <_M p^{[j]}$ fijar $p^{[j]} \rightarrow x^{[j]}$

35 (f) Si $x^{[j]} \notin F$ entonces seleccionar el $w \in M$ peor posible utilizando la relación $<_M$ y sustituir w por j en el sentido siguiente: $p^{[w]} \rightarrow x^{[j]} x^{[w]} \rightarrow x^{[j]} v^{[w]} \rightarrow v^{[j]}$. De esta manera se pueden generar buenas guías esclavas que están próximas al límite de factibilidad mejor que las maestras. Es posible que una buena maestra de buena puntuación lejos del límite pueda dar un óptimo global, de manera que no existe ninguna necesidad de sustituir sólo guías maestras que es probable que hayan sido generadas a partir de una esclava con preferencia a las maestras, en general.

40 Después de la sustitución de cada $w \in M$, se hallan las guías maestras utilizando la relación $<_M$.

5. 5. Después del procesamiento de cada esclava, se recalculan las ponderaciones de las limitaciones para asegurar que no existen puntos inviables de alta puntuación lejos del límite de factibilidad. Supongamos que $g \in ML$ es el óptimo global, es decir, $g \leq_M i$ para todos $i \in ML$.

45 (a) Si $g \notin F$ no existe un caso fiable de uso y de esta manera se duplican las ponderaciones de las limitaciones para motivar la selección de puntos fiables: $\mu_k \rightarrow 2\mu_k$.

(b) Si $g \notin F$ entonces se ajustan las ponderaciones de las limitaciones para asegurar que

$$Cl: s \in S \cap \bar{F} \Rightarrow \Theta(p^{[s]}) \geq f(p^{[g]}) \quad (62)$$

y las ponderaciones se reducen si existe demasiada holgura. Esto se hace de la siguiente manera:

50 i. Inicializar ajustando $ok \rightarrow \text{verdadero}$ y $\alpha \rightarrow 1$. ok es verdadero si no se ha hallado ningún caso que

infrinja la condición C1. α se utiliza para calcular la holgura en las ponderaciones de las limitaciones.

ii. Si $f(p^{[s]}) \geq f(p^{[g]})$ entonces se satisface la condición C1 automáticamente, puesto que $\Theta(x) \geq f(x)$.

iii. Para cada $s \in S \cap F[f(p^{[s]}) < f(p^{[g]})]$ hacer lo siguiente:

A. Poner $\Delta_1^s \rightarrow \Theta(p^{[s]}) - f(p^{[s]})$

5 B. Si $\Delta_1^s < 0$ fijar $ok \rightarrow false$ luego hallar k para dar $d_k(p^{[s]}) = \max_j = 1 \dots N_c(d_j(p^{[s]}))$ este máximo no es cero, por lo que podemos ajustar $\mu_k \rightarrow \mu_k + |\Delta_1^s|/d_k(p^{[s]})$, esto incrementa $\Phi(p^{[s]})$, de manera que se satisface justamente la condición C1.

C. Si $(\Delta_1^s \geq 0) \wedge ok$ entonces podemos calcular la holgura como

$$\alpha^s = \frac{f(p^{[g]}) - f(p^{[s]})}{\Theta(p^{[s]}) - f(p^{[s]})} \quad (63)$$

10 Éste debe ser un número positivo no cero y ponemos $\alpha \rightarrow \min(\alpha, \alpha^s)$, esto asegura que si ponemos $\mu_k \rightarrow \alpha \mu_k$ y recalculamos el coste aumentado $\Theta(x)$, entonces se satisface todavía la condición C1 en el caso de que ok permanezca verdadero.

15 iv. Después de procesar todos $s \in S \cap F[f(p^{[s]}) < f(p^{[g]})]$, verificar para ver si ok permanece verdadero y si de esta manera se reducen las ponderaciones de las limitaciones a la mitad de la holgura, colocando $\mu_k \rightarrow 0.5(1 + \alpha)\mu_k$.

20 Esto completa la descripción del algoritmo para una etapa de iteración sencilla. Como se puede ver, el algoritmo utiliza guías maestras y esclavas para alimentarse mutuamente de una manera que motiva a las maestras y a las esclavas a congregarse en el límite de factibilidad óptimo en el caso de que las limitaciones de factibilidad limiten el máximo global. Además, el algoritmo permite explorar dos soluciones competitivas al mismo tiempo utilizando guías más próximas en lugar de un óptimo global para guiar las geolocalizaciones maestras y esclavas. Además, el algoritmo ajusta las ponderaciones de las limitaciones para asegurar que las esclavas no tengan un mínimo global fuera del límite de factibilidad.

25 Utilizando una lista fija de $N_s + 1$ candidatos de geolocalizaciones, la implementación asegura que el algoritmo no produzca ineficiencias de gestión de la memoria. El repuesto uno se llama partícula de geolocalización aparcada, que se utiliza para generar nuevos casos de ensayo en la fase de actualización y las partículas de geolocalización son referenciadas por una matriz de punteros. La posición de la referencia en la matriz determina si estamos tratando con una esclava, maestra, o partículas de geolocalización aparcadas. La implementación asegura también que el maestro óptimo global esté siempre al comienzo de esta matriz de referencia encabezando la sub-matriz de maestros, de manera que es fácil tomar el mejor de los comandos de guía.

30 Un problema importante con el uso de un método de barrido hacia delante que comienza con un Costate estimado aproximado y se integra hacia delante para dar la guía predicha es que esto tiende a dar soluciones altamente complejas que están lejos de ser óptimas y, por lo tanto, requieren mucho esfuerzo. Puesto que un algoritmo de optimización separado solamente tiene que barrer hacia delante para estar exacto próximo a la solución óptima, se pueden introducir modificaciones en las ecuaciones diferenciales para impedir que las soluciones de seguimiento se onduen y den una estimación aproximada inicial inútil del óptimo.

35 Para conseguir el desrizado, se modifica la ecuación Costate para dar

$$\dot{\lambda}_\gamma = -\frac{\partial B}{\partial \gamma_m} + \lambda_x V_m \sin \gamma_m - \lambda_y V_m \cos \gamma_m - V_m (\lambda_x^2 + \lambda_y^2)^{1/2} k_s \lambda_\gamma \quad (64)$$

en la que k_s es una constante de iteración que se reduce a cero con iteraciones de geolocalizaciones para dar finalmente la solución correcta.

Para el análisis aproximado, suponemos que λ_x y λ_y son aproximadamente constantes y los términos de costes límites son bajos, entonces a partir de la Ecuación (64) obtenemos

$$\ddot{\gamma}_m = -\dot{\lambda}_y \quad (65)$$

$$\approx -A \sin(\gamma_m - \gamma_0) - A k_s \dot{\gamma}_m \quad (66)$$

5 donde

$$\lambda_x \equiv A \cos(\gamma_0) \quad (67)$$

$$\lambda_y \equiv A \sin(\gamma_0) \quad (68)$$

$$\Rightarrow A = V_m (\lambda_x^2 + \lambda_y^2)^{1/2} \quad (69)$$

Por comparación con la ecuación original. Linealizando obtenemos

$$10 \quad \ddot{\gamma}_m + A k_s \dot{\gamma}_m + A(\gamma_m - \gamma_0) = 0 \quad (70)$$

que es un sistema lineal de segundo orden con frecuencia natural

$$\omega = \sqrt{A} \quad (71)$$

y atenuando

$$\zeta = k_s \frac{\sqrt{A}}{2} \quad (72)$$

15 Típicamente, k_s es inicializada a 1 y se reduce exponencialmente a cero con una constante de tiempo de 50 iteraciones de geolocalización. De esta manera, las oscilaciones de alta frecuencia en la optimización ODE son atenuadas inicialmente fuertemente con preferencia a oscilaciones de baja frecuencia para motivar soluciones que es muy probable que sean óptimas, ya que las iteraciones continúan, se permiten las oscilaciones de alta frecuencia por la relajación de k_s cuando el algoritmo ha convergido y no es probable que se introduzcan oscilaciones salvajes no-óptimas. También se puede ver que el efecto de la función de coste ambiental B consiste en cambiar la frecuencia de la oscilación debido a gradientes en x_m y y_m y proporcionar una función de fuerza para perturbar el sistema, si B tiene un gradiente en γ_m .

25 Ahora contemplamos algunas cuestiones de implementación cuando se aplican a un ejemplo de planificación dinámica y consideramos algunos resultados. Esto muestra algunas propiedades emergentes interesantes, tales como la cobertura de dos resultados en diferentes instantes.

30 El ejemplo de planificación dinámica de la misión basado en las ecuaciones desarrolladas anteriormente está en un área de 10 km x 10 km como se muestra, por ejemplo, en la figura 1. En el Sur existe un aeródromo (no mostrado), donde el perseguidor es lanzado contra un objetivo que comienza en la torre central y puede emerger desde la zona urbana en muchas direcciones. El perseguidor es requerido para que evite las áreas de exclusión centradas sobre una aglomeración central de áreas urbanas y vuele sobre el objetivo reduciendo al mínimo al mismo tiempo la distancia errónea proyectada del suelo y maniobrando por el perseguidor. El objetivo es seguido por un rastreador con base en tierra que mide las demoras del alcance y Doppler y discrimina el objetivo con respecto al fondo a través de Doppler. El radar está situado en el aeródromo y mide la posición del objetivo cada 10 s. Se introduce también un intervalo de 10 s desde la medición y se genera la salida de guía dando al sistema tiempo para planificar hacia delante una trayectoria de 300 s en el futuro (desde el instante de inicio de la simulación). El radar tiene exactitudes de medición de rms de ángulo 8,5 mr, rango 20 m y Doppler 5 m/seg. Para un Doppler mayor que 2 m/seg, el rastreador puede medir el ángulo y el alcance del objetivo, mientras que para Doppler inferior a esto, solamente puede inferir la posición del objetivo por la medición Doppler. La guía basada en partículas planifica hacia

delante para predecir las mejores trayectorias futuras utilizando 5 iteraciones del algoritmo maestro-esclavo y una geolocalización de 40 casos de ensayo de optimización. Esto da un conjunto de Costates de ensayo predichos que se utiliza para inicializar la fase siguiente después de una medición y se utiliza la trayectoria óptima para producir comandos de navegación actuales. Las trayectorias de ensayo son soluciones óptimas candidatas e interactúan con el modelo de filtro de partículas del estado del objetivo utilizando las ecuaciones derivadas anteriormente con la excepción de que el gradiente próximo a los límites de exclusión han sido revertidos para proporcionar un conjunto de trayectorias más favorable. El uso del signo correcto tiende a hacer que las trayectorias ligeramente fuerza de pista reboten fuera de los límites de exclusión en lugar de abrazarlas, que sería el caso si se representasen correctamente las ecuaciones de limitaciones adicionales. Las trayectorias calculadas solamente se utilizan para proporcionar alternativas viables al optimizador maestro-esclavo y de esta manera se pueden modificar utilizando heurística, con tal que interfiera con la evaluación de coste importante.

El objetivo está confinado en el ejemplo para viajar sobre carreteras y se da dinámica de segundo orden con entrada aleatoria a lo largo de las líneas descritas por David Salmold, Martin Clark, Richard Vinter, y Simon Godsill ("Ground target modelling, tracking and prediction with road networks", technical report, the Defence Science and Technology Laboratory on behalf of the Controller of HMSO, 2007). Los objetivos tienen dinámicas que respetan la naturaleza de los enlaces de carreteras y se ralentizarán por término medio si, por ejemplo, un objetivo encuentra una carretera principal. Lo importante es que un modelo de comportamiento elaborado que es no-Gaussiano se puede acomodar fácilmente sin cambio significativo en el algoritmo. El Filtro de Partículas utiliza el filtro standard Sampling Importance Resampling (SIR) descrito por Branko Ristic y Sanjeev Arulampalam en "Beyond the Kalman Filter (Particle Filters for Tracking Applications)", Artech House, 2004) utilizando 1000 partículas. El número pequeño de partículas es posible en este caso debido a que el objetivo está restringido a carreteras y el algoritmo de guía promedia efectivamente sobre varias partículas.

El método empleado se establece como pseudocódigo en la figura 13. El método puede ser considerado como conjunto de bucles iterativos anidados. En el bucle de nivel alto (líneas 10 a 150 del pseudocódigo), se proporciona (línea 20) un conjunto de localizaciones posibles del objetivo (es decir, la distribución de probabilidades del objetivo), se calcula un control óptimo de guía (líneas 30 a 130) y se aplica el control de guía óptimo calculado al vehículo (línea 140). El vehículo recorre entonces una distancia a lo largo de su trayectoria en el mundo real, de acuerdo con el control de guía aplicado, antes de que se realicen otras observaciones del objetivo, y de esta manera se proporciona un conjunto revisado de posibles localizaciones del objetivo (retornando a la línea 20). El bucle se repite hasta que el vehículo alcanza el objetivo.

En el cálculo del control de guía óptimo (líneas 30 a 130), se itera un bucle de optimización durante un número predeterminado J de etapas. En el bucle de optimización, se proporcionan soluciones de guía candidatas (línea 40). Cada solución de guía candidata es considera a su vez (en un bucle en las líneas 50 a 110), y se calcula un coste para cada una en un bucle de cálculo del coste (líneas 60 a 90) y entonces se registra (línea 100). Una vez que todas las soluciones de guía candidatas han sido costeadas, se utiliza un algoritmo de optimización (en este ejemplo un algoritmo de geolocalización maestro-esclavo, como se ha descrito anteriormente) para calcular un nuevo conjunto de soluciones de guía candidatas (línea 120), que se utilizan en la siguiente iteración del bucle de optimización (por ejemplo, desde la línea 40).

En el bucle de coste (líneas 60 a 90), se calcula la trayectoria futura del vehículo que está siendo guiado (línea 70), para la solución de guía candidata, en este ejemplo por integración de la trayectoria Costate, de acuerdo con la Ecuación (21) anterior. A medida que se pasa el PONA para cada trayectoria posible del objetivo, se ajusta la trayectoria proyectada para tener en cuenta la trayectoria posible pasada del objetivo (línea 80), hasta que se pasa el PONA para la trayectoria final del objetivo, en cuyo punto se conoce el coste para la solución de guía candidata en consideración.

De esta manera, se calcula el coste para la trayectoria resultante de cada solución de guía candidata, y se determina la solución de guía óptima utilizando un algoritmo para optimizar ese coste.

El seguimiento de varios objetivos potenciales dispersos sobre una red de carreteras hace difícil apreciar las características cualitativas del algoritmo de seguimiento, de manera que se ha representado un vídeo del procesamiento interno trazado sobre el fondo de carreteras y áreas de exclusión y se ha registrado en un fichero .avi para reproducción. La figura 1 muestra una instantánea de un cuadro de este tipo, anotado con comentarios adicionales. El tiempo de barrido es el tiempo de estado predicho interno desde el comienzo de la simulación. El tiempo de medición corresponde al siguiente tiempo de medición. Todas las salidas representan el estado después de 5 iteraciones del algoritmo maestro-esclavo, donde existen 20 maestros y 20 esclavos. Las líneas verdes 10 representan el óptimo personal de los maestros, con la trayectoria roja 20 representando la mejor predicción de la trayectoria global. La trayectoria negra 30 representa la trayectoria real tomada hasta ahora por la munición. La red de carreteras se representa por líneas naranjas 40. Las carreteras gruesas representan carreteras principales, donde el objetivo se puede mover a velocidades medias más rápidas. Las zonas de exclusión son representadas por contornos horarios púrpura 50. La trayectoria del objetivo hasta ahora se representa por una trayectoria azul clara

60, la posición actual del objetivo sincronizada con el tiempo de barrido se representa por un círculo amarillo 70 y la distribución predicha del objetivo se representa por puntos azules oscuros 80.

En el ejemplo Caso 1, el objetivo comienza a moverse en dirección Sur, como se muestra en la figura 2, y es interceptado bastante pronto. La figura 3 muestra la distribución potencial del objetivo en este tiempo de intercepción, si no existieran mediciones futuras. No obstante, el algoritmo no toma precisamente una localización media de posiciones posibles del objetivo que resultan en vuelo directamente a la zona de exclusión. Hay que observar que las 5 etapas iniciales en la optimización no han convergido en una solución óptima a largo plazo, sino que esto tiene poco efecto en la trayectoria actual tomada.

La figura 4 muestra un conflicto de rutas potenciales del objetivo y el planeador comienza a seleccionar el tiempo más corto para ir a la casilla primera. Esto sucede debido a que el algoritmo tenderá a aproximarse cuando se elija un PONA. En la figura 5, esto se resuelve en una pata de perro que cubre la trayectoria que va al Sur y una trayectoria Este-Oeste.

La trayectoria que va al Sur no se materializa y en la figura 6 el planeador se concentra en las trayectorias Este-Oeste. Finalmente, en la figura 7, la munición se aloja en el objetivo.

En el ejemplo Caso 2, el objetivo comienza en el centro de la zona de exclusión como se muestra en la figura 8 y finalmente emerge en la cabecera superior Noroeste. En la figura 9, el planeador explora dos opciones y decide ir al Oeste del área de exclusión. Este caso muestra cómo se pueden bifurcar las soluciones.

En la figura 10 la ruta Oeste se convierte en la única opción, pero la trayectoria no se dobla ya hacia los objetivos, por que el coste debido a la distancia errónea ha sido saturado y solamente influye fuertemente en la trayectoria planeada de corto alcance. En este caso, los Costates han cargado significativamente para dar una trayectoria recta más allá de la zona de exclusión. Existe una contribución de coste incorporada para asegurar que los Costates finales al término de las trayectorias planeadas son cero, lo que debería ser el caso para una solución óptima. Sin embargo, este componente de coste no elimina esta tendencia de carga. Finalmente, se pasa el área central de exclusión y el planeador se mueve hacia las posiciones restantes posibles del objetivo en la figura 11. Finalmente, en la figura 12, el planeador se aloja sobre el centro de la distribución del objetivo.

De esta manera, se ha producido un método práctico para resolver el problema general de abordar problemas de guía no-Gaussiana. El método ha sido aplicado al problema ejemplar de planificación dinámica de misiones de persecución de un vehículo aéreo contra un objetivo móvil en tierra, restringido a moverse sobre una red de carreteras.

El algoritmo maestro-esclavo para hallar una trayectoria óptima, junto con la parametrización óptima modificada de la trayectoria por Costate que interactúa con representación de filtro de partículas de la capacidad del objetivo, da un buen método para hallar soluciones aplicables para navegar hacia objetivos en tierra sobre una red de carreteras, donde existe una incertidumbre significativa en el movimiento futuro del objetivo en la presencia de áreas de exclusión. El algoritmo maestro-esclavo tiene un componente de búsqueda aleatoria y solamente proporciona una solución aproximada de una manera que es similar al uso de partículas en el filtrado de partículas para representar distribuciones de probabilidades del objetivo. Como tal, es útil en la producción de entrada de navegación bruta a la guía, y en el caso de un rastreador de radar externo, la munición utiliza un sensor de corto alcance para adquirir el objetivo a 500 m para ir y alojarse en el objetivo utilizando seguimiento del rumbo convencional. Los resultados en el ejemplo descrito muestran cierto comportamiento emergente interesante: las posiciones posibles opcionales del objetivo son cubiertas por maniobras de pata de perro adecuadas utilizando buena sincronización, y las trayectorias opcionales alternativas son cubiertas por la geolocalización de trayectorias planificadas.

Formas de realización de la invención pueden abordarse, por lo tanto, con el caso en el que existen varias trayectorias posibles del objetivo a seleccionar y donde existe una diferencia significativa en el tiempo de vuelo para cada trayectoria y el coste depende de la mezcla ponderada de objetivos posibles. Esto permite a formas de realización de la invención tratar con futuro incierto con una distribución conocida de probabilidades de casos, donde la estimación del objetivo y la guía óptima no se pueden separar en problemas independientes.

Con respecto a una "diferencia significativa en el tiempo de vuelo" mencionada anteriormente, el tiempo de vuelo hasta un objetivo ("tiempo de marcha") es el tiempo total de vuelo hasta un PONA seleccionado correspondiente para una trayectoria de muestra del objetivo. Las trayectorias del objetivo pueden estar afectadas por uno o más factores físicos, siendo éstos, por ejemplo, la geografía de las trayectorias propiamente dichas del objetivo y el efecto de áreas de exclusión para el perseguidor. En formas de realización de la invención, la diferencia entre tiempos de marcha se puede reducir seleccionando la muestra de objetivo grande y, por lo tanto, se prefiere una diferencia pequeña, pero esto incrementa el número de PONAs y el número de saltos. Cada salto añade coste. Formas de realización de la invención funcionan particularmente bien donde la dispersión del tiempo de marcha hasta un PONA para las trayectorias de objetivos individuales con relación a un tiempo medio de marcha para todas

las trayectorias de los objetivos es significativa. Se puede decir que éste es el caso si la hipótesis de que todos los tiempos de marcha son iguales conduce a un incremento significativo en el coste general de actuación. En general, esto ocurre si existe una dispersión del orden del 30% o más en los tiempos de vuelo para las trayectorias individuales de los objetivos con respecto al tiempo medio de vuelo. Formas de realización de la invención son particularmente útiles, por ejemplo, donde un perseguidor se demora con el fin de obtener un mejor disparo en el objetivo, mientras que la incertidumbre en la posición del objetivo (dos o tres rutas de salida diferentes disponibles desde un área de exclusión, por ejemplo) significa que el perseguidor tiene que cubrir más de una ruta hacia el objetivo.

- 5
- 10

15

REIVINDICACIONES

- 1.- Un método de guía de un perseguidor hacia un objetivo, comprendiendo el método:
 - 5 (a) proporcionar una pluralidad de trayectorias de objetivos posibles, ponderadas para representar una distribución de probabilidades de las trayectorias de los objetivos;
 - (b) proporcionar una pluralidad de controles de guía candidatos, parametrizados por un parámetro de guía candidato;
 - 10 (c) para cada uno de una pluralidad de valores de los parámetros de guía candidatos:
 - a. determinar una trayectoria proyectada del perseguidor, que resulta del control de guía candidato que corresponde al valor del parámetro de guía candidato;
 - b. utilizando la trayectoria proyectada del perseguidor desarrollada hasta ahora, determinar la siguiente aparición de una condición de terminación para la trayectoria del perseguidor relativa a una cualquiera de las trayectorias del objetivo para las que no ha aparecido todavía una condición de terminación;
 - 15 c. ajustar la trayectoria proyectada del perseguidor, a continuación de esa aparición de la condición de terminación, para tener en cuenta esta trayectoria del objetivo;
 - d. repetir las etapas b y c hasta que hayan sido tenidas en cuenta las condiciones de terminación que corresponden a toda la pluralidad de trayectorias posibles de los objetivos; y
 - 20 e. registrar un coste para el control de guía candidato sobre la base de la trayectoria proyectada del perseguidor y las distancias erróneas a la aparición de la condición de terminación para cada trayectoria del objetivo;
 - (d) generar una pluralidad revisada de valores de los parámetros de guía candidatos a la vista de los costes registrados de los controles de guía candidatos.
 - 25 (e) repetir las etapas (c) y (d) una pluralidad de veces e identificar un control de guía óptimo sobre la base de los costes registrados;
 - (f) aplicar el control de guía óptimo sobre el perseguidor para alterar su trayectoria actual;
 - (g) obtener trayectorias posibles actualizadas de objetivos; y
 - (h) repetir las etapas (b) a (g) una pluralidad de veces.
- 30 2.- Un método de acuerdo con la reivindicación 1, en el que la condición de terminación relativa a una trayectoria del objetivo es el punto de la aproximación siguiente de la trayectoria proyectada del perseguidor con relación a la trayectoria del objetivo.
- 3.- Un método de acuerdo con la reivindicación 1 ó 2, en el que el parámetro de guía candidato es un parámetro Costate.
- 35 4.- Un método de acuerdo con una cualquiera de las reivindicaciones precedentes, en el que las trayectorias del objetivo se describen por medio de estadísticas no-gaussiana.
- 5.- Un método de acuerdo con la reivindicación 4, en el que las trayectorias del objetivo son rutas posibles de un vehículo objetivo.
- 6.- Un método de acuerdo con una cualquiera de las reivindicaciones precedentes, en el que la pluralidad revisada de valores de los parámetros de guía candidatos son generados utilizando un algoritmo de optimización.
- 40 7.- Un método de acuerdo con una cualquiera de las reivindicaciones precedentes, en el que el algoritmo de optimización es un algoritmo de geolocalización.
- 8.- Un método de acuerdo con la reivindicación 7, en el que el algoritmo de geolocalización es un algoritmo de geolocalización maestro-esclavo.
- 45 9.- Un método de acuerdo con una cualquiera de las reivindicaciones precedentes, que comprende re-direccionar una trayectoria proyectada atenuando una oscilación de alta frecuencia en la trayectoria proyectada.
- 10.- Un método de acuerdo con una cualquiera de las reivindicaciones precedentes, en el que dicha pluralidad de trayectorias posibles del objetivo proporcionadas en la etapa (a) comprenden un número de trayectorias discretas posibles.
- 50 11.- Un método de acuerdo con la reivindicación 10, en el que dichas trayectorias discretas posibles comprenden rutas de carretera (40).
- 12.- Un método de acuerdo con una cualquiera de las reivindicaciones 2 a 11, en el que para dicha pluralidad de trayectorias posibles del objetivo proporcionadas en la etapa (a), el tiempo de vuelo hasta un punto correspondiente más próximo para la trayectoria del perseguidor con relación a cada una de las trayectorias del objetivo permite una

dispersión del orden del 30 % o más con respecto al tiempo medio de vuelo para todas las trayectorias del objetivo.

13.- Un método de acuerdo con una cualquiera de las reivindicaciones precedentes, que comprende, además, proporcionar una o más limitaciones del estado del perseguidor, de tal manera que cada coste registrado en la etapa (e) para el control de guía candidato está sujeto a dicha(s) limitaciones del estado del perseguidor.

- 5 14.- Aparato de procesamiento dispuesto para realizar las etapas de un método de acuerdo con una cualquiera de las reivindicaciones anteriores.

15.- Un vehículo que comprende el aparato de procesamiento de acuerdo con la reivindicación 14.

Fig.1.






Fig.2.




tiempo de barrido : 10 tiempo de medida = 0 iteración = 5

Fig.3.




tiempo de barrido : 100 tiempo de medida = 0 iteración = 5

Fig.4.




tiempo de barrido : 130 tiempo de medida = 10 iteración = 5

Fig.5.



tiempo de barrido : 120 tiempo de medida = 30 iteración = 5

Fig.6.



tiempo de barrido : 100 tiempo de medida = 70 iteración = 5

Fig.7.






Fig.8.



tiempo de barrido : 10 tiempo de medida = 0 iteración = 5

Fig.9.



tiempo de barrido : 170 tiempo de medida = 40 iteración = 5

Fig.10.






Fig.11.



tiempo de barrido : 160 tiempo de medida = 120 iteración = 5

Fig.12.



tiempo de barrido : 160 tiempo de medida = 140 iteración = 5

FIGURA 13

EJEMPLO DE MÉTODO

BUCLE DE GUIA Y OBSERVACIÓN

10 Repetición:

20 Proporcionar localizaciones posibles del objetivo

BUCLE DE OPTIMIZACIÓN

30 Para J = 1 hasta N° de etapas de iteración

40 Proporcionar soluciones candidatas

BUCLES CANDIDATOS

50 Para K = 1 hasta N° de candidatos

BUCLE DE COSTE

60 Repetir:

70 Calcular trayectoria Costate hasta que se alcance un PONA del objetivo

80 Ajustar Costate para desechar objetivo pasado

90 Hasta que se alcanza el PONA final del objetivo

100 Registrar coste de la solución candidata

110 Siguiendo K

120 Calcular nuevas soluciones candidatas

130 Siguiendo J

140 Aplicar control de guía óptimo calculado

150 Hasta que se alcanza el objetivo