

19) RÉPUBLIQUE FRANÇAISE  
INSTITUT NATIONAL  
DE LA PROPRIÉTÉ INDUSTRIELLE  
PARIS

11) N° de publication : **2 887 385**  
(à n'utiliser que pour les  
commandes de reproduction)

21) N° d'enregistrement national : **05 06089**

51) Int Cl<sup>8</sup> : H 04 L 12/26 (2006.01), G 06 F 12/14, 17/30

12) **DEMANDE DE BREVET D'INVENTION**

**A1**

22) Date de dépôt : 15.06.05.

30) Priorité :

43) Date de mise à la disposition du public de la demande : 22.12.06 Bulletin 06/51.

56) Liste des documents cités dans le rapport de recherche préliminaire : *Se reporter à la fin du présent fascicule*

60) Références à d'autres documents nationaux apparentés :

71) Demandeur(s) : *ADVESTIGO Société anonyme — FR.*

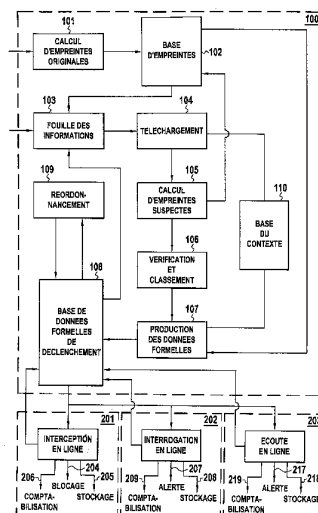
72) Inventeur(s) : PIC MARC, FISCHER DAVID, NAVARRE MICHEL et TILMONT CHRISTOPHE.

73) Titulaire(s) :

74) Mandataire(s) : CABINET BEAU DE LOMENIE.

54) **PROCEDE ET SYSTEME DE REPERAGE ET DE FILTRAGE D'INFORMATIONS MULTIMEDIA SUR UN RESEAU.**

57) Le procédé de repérage et de filtrage d'informations multimédia consiste à surveiller hors ligne sur un réseau de transmission de données, des informations multimédia par rapport à des informations multimédia de référence et à réaliser à l'aide d'un module d'intervention en ligne une interception, une interrogation ou une écoute en ligne d'informations multimédia reconnues au moyen de données formelles stockées dans une base de données formelles de déclenchement produite lors de la surveillance hors ligne à partir d'informations suspectes obtenues lors d'une fouille des informations multimédia sur le réseau.



FR 2 887 385 - A1



La présente invention a pour objet un procédé et un système de  
5 repérage et de filtrage d'informations multimédia sur un réseau de  
transmission de données.

On constate sur des réseaux tels que la toile mondiale (web)  
une prolifération d'échanges illégaux de contenus, notamment dans le  
cadre d'échanges poste à poste (P2P) et dans le cadre de places de  
10 marché électronique.

On a déjà proposé d'effectuer un filtrage protocolaire afin de  
repérer des utilisateurs du protocole P2P. Toutefois, le protocole visé par  
le filtrage n'est pas illégal par lui-même et on ne peut donc bloquer un tel  
protocole dans son intégralité, dès lors qu'il est à même de faire transiter  
15 aussi bien des données légales que des données illégales.

On a également proposé d'effectuer des interceptions  
d'informations multimédia sur un réseau en procédant par reconnaissance  
du contenu.

Pour effectuer une interception par reconnaissance de contenu  
20 audio, vidéo ou image, on ne peut toutefois pas se contenter de procéder  
à des identifications de signatures exactes, telles que celles qui sont  
effectuées avec des stratégies de vérification de somme de contrôle ou  
celles qui font appel à une fonction de hachage comme l'algorithme de  
signature MD5 (Message Digest 5). En effet, la modification de quelques  
25 bits d'un fichier musical par exemple peut rendre inopérante une signature  
telle qu'une signature MD5 alors que le contenu du fichier modifié est  
encore parfaitement reconnaissable et exploitable par l'oreille humaine.

Par ailleurs, un procédé généralisé de contrôle exhaustif et  
systématique de toutes les transactions poste à poste constitue un  
30 mécanisme très lourd technologiquement si l'on veut filtrer l'intégralité des  
échanges s'opérant sur un réseau.

Les solutions de filtrage généralistes déjà proposées consistent  
essentiellement soit à bloquer les ports courants des échanges poste à  
poste, soit à détecter des échanges se faisant sur ces protocoles P2P.  
35 Toutefois, il est relativement facile de modifier le contexte de déploiement  
d'un protocole P2P, comme par exemple changer le port des

communications pour éviter les filtrages. Par ailleurs, comme on l'a  
indiqué plus haut, il est difficilement imaginable, au niveau d'un  
fournisseur d'accès Internet, d'appliquer une règle de filtrage des  
protocoles P2P dans leur totalité à partir du moment où le protocole lui-  
même n'est pas illégal, que ce n'est que l'usage qui en est fait dans  
5 certains cas qui est illégal et que des contenus parfaitement légaux (par  
exemple des logiciels ou des codes sources libres de droit) sont échangés  
par ce biais.

Il existe donc un besoin pour effectuer un repérage et un  
10 filtrage de contenus prohibés sur des réseaux poste à poste ("peer-to-  
peer" ou P2P), d'une manière efficace et cependant technologiquement  
simple, et qui ne porte pas atteinte aux échanges poste à poste  
concernant des contenus parfaitement légaux.

Il existe également un besoin pour repérer et filtrer des  
15 annonces de produits contrefaits sur des places de marché électronique.

Les places de marché électronique, telles que des sites  
d'enchères en ligne, permettent la diffusion de produits contrefaits qui  
échappent aux services de police et de douanes de par la fragmentation  
de leur diffusion. Un revendeur de tels produits situé dans un pays donné  
20 peut s'enregistrer sous différentes identités d'emprunt et sous ce couvert  
commercialiser par petits lots, donc difficilement repérables, des produits  
contrefaits.

Il est donc nécessaire de pouvoir repérer et filtrer ces offres de  
produits contrefaits afin par exemple d'envoyer un avertissement en cas  
25 de détection de messages ayant un contenu illégal, tels que des annonces  
de produits contrefaits.

L'invention a ainsi pour objet de remédier aux inconvénients  
précités et de permettre de récupérer et de filtrer des informations  
multimédia sur un réseau de transmission de données numériques tel que  
30 l'Internet, d'une façon à la fois simple et efficace sans qu'il soit nécessaire  
de filtrer l'intégralité des échanges s'opérant sur le réseau.

Ces buts sont atteints, conformément à l'invention, grâce à un  
procédé de repérage et de filtrage d'informations multimédia sur un  
réseau de transmission de données, caractérisé en ce qu'il comprend les  
35 étapes suivantes :

- a) surveiller hors ligne des informations multimédia par rapport à des informations multimédia de référence, avec les étapes suivantes :
- a1) calculer des empreintes originales des informations multimédia de référence,
  - 5 a2) stocker les empreintes originales de référence calculées dans une base d'empreintes,
  - a3) fouiller des informations multimédia sur le réseau et télécharger des informations suspectes,
  - 10 a4) calculer des empreintes suspectes des informations multimédia suspectes,
  - a5) vérifier les empreintes suspectes par rapport aux empreintes originales et regrouper les empreintes suspectes en classes par rapprochement des empreintes similaires,
  - 15 a6) produire des données formelles avec une affectation de priorité par classe d'empreintes et stocker les données formelles dans une base de données formelles de déclenchement,
  - a7) alimenter par intermittence au moins un module d'intervention en ligne sur le réseau avec une copie au moins partielle de la base de données formelles de déclenchement,
  - 20 b) effectuer au moins l'une des opérations suivantes à l'aide du module d'intervention en ligne :
  - b1) intercepter en ligne des informations multimédia reconnues au moyen des données formelles présentes dans la base de données formelles de déclenchement et décider soit d'autoriser le passage, soit de provoquer le blocage des informations multimédia reconnues,
  - 25 b2) interroger en ligne des informations multimédia reconnues au moyen des données formelles présentes dans la base de données formelles de déclenchement et procéder au moins à une comptabilisation ou à un stockage des informations multimédia reconnues, ou à un déclenchement d'alerte lors de la reconnaissance des informations multimédia,
  - 30 b3) écouter en ligne des informations multimédia reconnues au moyen des données formelles présentes dans la base de données formelles de déclenchement et procéder au moins à une comptabilisation ou à un stockage des informations
  - 35

multimédia reconnues, ou à un déclenchement d'alerte lors de la reconnaissance des informations multimédia.

Avantageusement, on procède de façon périodique à un tri et un ordonnancement des données formelles de déclenchement de la base de données formelles, en sélectionnant les données formelles les plus importantes en fonction d'au moins un critère de priorité.

De préférence, lors d'une opération d'interception en ligne, d'écoute en ligne ou d'interrogation en ligne, on procède de façon périodique à une mise à jour des données formelles stockées dans la base de données formelles de déclenchement, à partir de données statistiques obtenues lors de l'opération d'interception en ligne, d'écoute en ligne ou d'interrogation en ligne.

Selon une caractéristique avantageuse, après l'étape de fouille des informations multimédia sur le réseau et le téléchargement des informations suspectes, on procède à un filtrage des informations multimédia suspectes à l'aide d'au moins un entête de sélection prédéterminé, et on ne procède au calcul des empreintes suspectes que pour les informations multimédia suspectes satisfaisant le critère de sélection prédéterminé.

Selon un mode particulier de réalisation, ledit critère de sélection prédéterminé comprend au moins l'un des éléments de sélection suivants pour un fichier contenant des informations multimédia suspectes : le type de fichier selon la nature du média qu'il comporte, l'état de corruption du fichier, la taille du contenu du fichier.

Avantageusement, on calcule des empreintes originales des informations multimédia de référence et des empreintes suspectes des informations multimédia suspectes selon le même procédé, mais on détermine des empreintes suspectes présentant des caractéristiques simplifiées par rapport à celles des empreintes originales.

Selon une autre caractéristique particulière, on modifie régulièrement l'adresse IP à partir de laquelle on procède à une fouille sur le réseau et un téléchargement afin de créer une anonymisation des échanges.

Selon un mode particulier de réalisation, pour réaliser l'interception en ligne des informations multimédia, on fait transiter les paquets de données présents sur le réseau de façon conditionnelle dans

un module d'interception comprenant un étage tampon pour conserver de façon temporaire un paquet de données entrant, un étage d'analyse d'un paquet de données et un étage de déclenchement pour autoriser la transmission du paquet de données analysé ou décider de son rejet, et  
5 commander ensuite l'effacement du paquet dans l'étage tampon et l'introduction d'un paquet suivant dans l'étage d'analyse.

Dans ce cas, dans le module d'interception, on procède avantagement à un filtrage préalable des paquets issus de l'étage tampon avant leur introduction dans l'étage d'analyse.

10 Selon une caractéristique particulière, dans le module d'interception, on utilise l'étage de déclenchement pour enregistrer en outre des données statistiques concernant les paquets rejetés ou transmis.

Selon un mode particulier de réalisation de l'invention, pour réaliser l'interrogation en ligne des informations multimédia, on procède à  
15 une interrogation ou une exploration du contenu d'un serveur web ou poste à poste à partir de requêtes, on procède à une comparaison des données collectées en réponse à ces requêtes avec celles de la base de données formelles de déclenchement et, en fonction du résultat de la comparaison, on déclenche une alerte, on collecte des informations ou on  
20 s'abstient d'intervenir.

Selon encore un autre mode particulier de réalisation de l'invention, pour réaliser l'écoute en ligne des informations multimédia, on procède au sein d'un serveur mandataire d'une part à l'écoute de requêtes de clients et à la recopie de ces requêtes et des données collectées en  
25 réponse à ces requêtes, et d'autre part à la transmission transparente de données entre client et serveur, on procède à une comparaison des données collectées recopiées avec celles de la base de données formelles de déclenchement et en fonction du résultat de la comparaison, on déclenche une alerte, on collecte des informations ou on s'abstient  
30 d'intervenir.

Dans les modes de réalisation précédents, on procède avantagement à un filtrage préalable des données collectées avant d'effectuer leur comparaison avec celles de la base de données formelles de déclenchement.

35 Selon une application particulière du procédé selon l'invention, l'étape consistant à fouiller des informations multimédia sur le réseau et

télécharger des informations suspectes est effectuée sur des contenus poste à poste proposés à l'échange, les données formelles comprennent des codes de hash, et l'interception ou l'écoute s'effectue en un point d'écoute du réseau poste à poste par extraction en temps réel des codes de hash des paquets de données d'échanges poste à poste.

5

L'invention a encore pour objet un système de repérage et de filtrage d'informations multimédia sur un réseau, caractérisé en ce qu'il comprend :

- un module de surveillance hors ligne des informations multimédia par rapport à des informations multimédia de référence, lequel module de surveillance hors ligne comprend au moins :

10

- un module de calcul d'empreintes originales des informations multimédia de référence,

15

- un module de stockage des empreintes originales de référence calculées,

- un module de fouille des informations multimédia sur le réseau,

- un module de téléchargement des informations suspectes détectées,

20

- un module de calcul des empreintes suspectes des informations multimédia suspectes téléchargées,

- un module de stockage des empreintes suspectes calculées,

25

- un module de vérification et de regroupement des empreintes suspectes en classes,

- un module de production de données formelles avec une affectation de priorité par classes d'empreintes, et

- un module de stockage des données formelles constituant une base de données formelles de déclenchement,

30

et au moins l'un des modules suivants d'intervention en ligne sur le réseau :

a) un module d'interception en ligne comprenant au moins

- un module de stockage local d'au moins une partie de la base de données formelles de déclenchement,

35

- un module tampon,

- un module d'analyse et de comparaison entre les données issues du module tampon et les données stockées dans le module de stockage local,
  - un module de déclenchement réagissant aux informations fournies par le module d'analyse, et
  - un module de transmission sélective des informations multimédia reconnues, activé par le module de déclenchement,
- b) un module d'interrogation en ligne comprenant au moins :
- un module de stockage local d'au moins une partie de la base de données formelles de déclenchement,
  - un module de requête fournissant des données collectées en réponse à des requêtes,
  - un module d'analyse et de comparaison entre lesdites données collectées en réponse et les données stockées dans le module de stockage local,
  - un module de déclenchement réagissant aux informations fournies par le module d'analyse, et
  - un module d'émission d'une alerte, de comptabilisation ou de stockage des informations multimédia reconnues, activé par le module de déclenchement,
- c) un module d'écoute en ligne comprenant au moins :
- un module de stockage local d'au moins une partie de la base de données formelles de déclenchement,
  - un serveur mandataire d'écoute de requêtes de clients et de copie des requêtes et des données collectées en réponse aux requêtes,
  - un module d'analyse et de comparaison entre lesdites données collectées en réponse et les données stockées dans le module de stockage local,
  - un module de déclenchement réagissant aux informations fournies par le module d'analyse,
  - un module d'émission d'une alerte de comptabilisation ou de stockage des informations multimédia reconnues, activé par le module de déclenchement.



Selon une caractéristique particulière, le module d'interception en ligne comprend en outre un module d'émission d'une alerte, de comptabilisation ou de stockage des informations multimédia reconnues, activé par le module de déclenchement.

5           Avantageusement, le module de surveillance hors ligne comprend en outre un module de réordonnancement périodique des données formelles de déclenchement de la base de données formelles.

10           Selon un mode de réalisation particulier, le module d'interception en ligne, le module d'interrogation en ligne et le module d'écoute en ligne comprennent en outre chacun un module de filtrage disposé en entrée du module d'analyse.

15           L'invention s'applique d'une manière générale au repérage et au filtrage d'informations multimédia sous forme numérique pouvant comporter aussi bien des images, du texte, des signaux audio, des signaux vidéo ou un mélange de ces différents types de contenus.

D'autres caractéristiques et avantages de l'invention ressortiront de la description suivante de modes particuliers de réalisation, donnés à titre d'exemples, en référence aux dessins annexés, sur lesquels :

20           - la Figure 1 est un schéma-bloc montrant les principaux éléments constitutifs d'un exemple de système conforme à l'invention pour effectuer le repérage et le filtrage d'informations multimédia sur un réseau,

25           - la Figure 2 est un schéma-bloc montrant un exemple de réalisation de module d'interception en ligne utilisable dans le système de la Figure 1,

            - la Figure 3 est un schéma-bloc montrant un exemple de réalisation de module d'interrogation en ligne utilisable dans le système de la Figure 1,

30           - la Figure 4 est un schéma-bloc montrant un exemple de réalisation de module d'écoute en ligne utilisable dans le système de la Figure 1,

            - la Figure 5 est un schéma-bloc montrant un exemple d'application de l'invention au repérage et au filtrage d'annonces de produits contrefaits sur des places de marché électroniques,

- la Figure 6 est un schéma-bloc montrant un exemple d'application de l'invention au repérage et au filtrage de contenus prohibés sur des réseaux poste à poste.

5 On décrira d'abord d'une manière générale le procédé et le système selon l'invention qui permettent d'effectuer le repérage et le filtrage d'informations multimédia sur un réseau de transmissions de données numériques, tel que le réseau Internet, qui peut mettre en œuvre aussi bien des serveurs web que des serveurs poste à poste (P2P).

10 L'invention met en œuvre d'une part un premier ensemble 100 de surveillance hors ligne, c'est-à-dire sans contrainte de temps, des informations multimédia par rapport à des informations multimédia de référence et d'autre part un ou plusieurs modules 201, 202, 203 délocalisés d'intervention en ligne sur le réseau, c'est-à-dire agissant en temps réel.

15 Selon l'invention, au sein du module de surveillance hors ligne 100, une première étape consiste, à partir de document originaux faisant l'objet d'une protection, par exemple parce qu'ils bénéficient de droits d'auteur ou d'autres droits de propriété intellectuelle, à calculer des empreintes approchées de ces documents originaux de référence (module  
20 101). Ces empreintes originales calculées sont ensuite stockées dans une base d'empreintes 102.

Pour la caractérisation des documents multimédia originaux à l'aide d'empreintes approchées, on peut utiliser divers procédés d'indexation et d'identification, tels que par exemple le procédé décrit  
25 dans la demande de brevet FR 2 863 080 qui donne plusieurs exemples prenant en compte les différents types de médias pouvant apparaître indépendamment ou en combinaison dans un document transmis sur un réseau de transmission de données numériques : audio, vidéo, images fixes, texte.

30 Dans une autre étape du procédé selon l'invention mise en œuvre dans le module de surveillance hors ligne 100, on procède à une fouille des informations multimédia sur le réseau (module 103) et on procède au téléchargement des informations suspectes repérées à partir des informations fournies au module de fouille 103 par la base  
35 d'empreintes 102.

Le module de fouille 103 fouille ainsi les informations multimédia sur le réseau par interrogation de serveurs, qu'il s'agisse de serveurs web ou de serveurs poste à poste. Cette interrogation est menée à partir de requêtes générées automatiquement par le système au sein du module de fouille 103.

Le système peut ainsi procéder d'abord par extraction de mots-clefs depuis les informations contenues dans la liste des empreintes originales de la base d'empreintes 102 : extraction de mots des titres, informations connexes, contexte, type de contenu,...

Ces mots-clefs sont filtrés par pertinence et rareté grâce à des dictionnaires de fréquence. Les mots-clefs restants sont ensuite associés suivant différentes combinaisons directes pour produire des requêtes.

Différentes stratégies peuvent être employées, selon le contexte, pour retrouver des contenus suspects sur le réseau, à l'aide du module 103 de fouille des informations.

Dans le cas du contexte de réseaux poste à poste, dans lesquels chaque terminal est configuré pour servir à la fois de serveur et de client et deux terminaux en réseau P2P peuvent ainsi s'échanger des fichiers sans passer par un serveur central de redistribution de données, le système selon l'invention interroge avec les requêtes générées au sein du module de fouille 103 les serveurs de différents protocoles P2P pour obtenir les mises à disposition de contenus proposés par les intervenants.

Les serveurs P2P retournent au module 103 différentes propositions de mise à disposition caractérisées par des identifiants uniques fournis par un serveur P2P.

Le module de fouille 103 élimine alors les propositions ne correspondant pas aux besoins de l'enquête, par filtrage de certains mots-clefs ou de certains types de documents (on peut par exemple rejeter les fichiers se terminant par .exe).

De façon optionnelle, par interrogation de la base de données formelles de déclenchement 108, qui sera décrite plus loin, le module de fouille 103, en prenant en compte les données formelles déjà constituées, peut éliminer les propositions qui présentent des informations formelles identiques à celles déjà présentes dans la base de données formelles 108.

Le module de fouille 103 peut alors retrouver les machines d'internautes mettant à disposition des contenus suspects correspondant totalement ou partiellement aux documents originaux de référence.

5 Dans le module 104, le téléchargement des contenus suspects s'effectue de manière totale ou partielle, mais en quantité suffisante pour permettre la reconnaissance de contenus au moyen des mécanismes de production et vérification d'empreintes suspectes qui seront décrits plus loin en référence aux modules 105 à 107.

10 Dans le cas du contexte d'un réseau tel que le web, le module de fouille 103 explore les serveurs web définis dans les cibles.

A titre d'option, le module de fouille 103 peut d'abord interroger des serveurs web de référence pour découvrir de manière automatique les liens décrivant les serveurs web recherchés. L'interrogation de ces serveurs cibles se fait au moyen de requêtes qui sont produites de la même manière que dans le contexte P2P.

15 L'exploration des serveurs web définis dans les cibles s'effectue en téléchargeant une page web, en analysant le contenu de cette page, en découvrant les liens inclus dans celle-ci, en filtrant ces liens suivant certains critères, en téléchargeant les pages correspondant à ces liens et ainsi de suite récursivement jusqu'à avoir rempli un critère d'arrêt tel qu'un nombre de pages parcourues ou une profondeur de descente dans l'arborescence du site. Les pages web sont téléchargées avec l'ensemble de leur contenu associé (image, sons, vidéo, fichiers, etc.) ou avec seulement certaines catégories de ces médias.

25 Le filtrage des liens au sein des pages peut se faire au moyen d'une connaissance "a priori" du site. Par exemple, on peut savoir que les liens amenant à des publicités présentent une forme ou une syntaxe particulière, et on peut ainsi les éliminer de la fouille par ces critères.

30 On peut par ailleurs déclencher l'exploration d'un site non pas sur une page initiale que l'on fouille exhaustivement et récursivement, mais au contraire programmer un cheminement précis de l'exploration pour être à même d'extraire seulement certaines informations de site. Par exemple, un site présentant des listes de réponses organisées avec pour chaque réponse un lien utile et des liens décoratifs (images, résumés,...) 35 pourra être exploité en définissant comme chemin d'exploration des règles

d'analyse syntaxique précises ne retenant que les balises entourant les liens utiles et rejetant les autres.

La navigation entre plusieurs pages peut également être automatisée si l'on mélange les règles syntaxiques pour décider si un lien mérite d'être exploré ou non, et des règles de navigation qui vont préciser comment aller à une certaine page évoquée dans un lien même si le lien ne mène pas directement à cette page.

Ces règles de navigation peuvent également permettre de programmer la navigation vers des liens qui ne sont pas indiqués dans le document mais peuvent être découverts par interpolation. Par exemple, si deux liens d'une page évoquent des pages dénommés `index2.html` et `index4.html`, on pourra alors avantageusement chercher une page `index3.html`.

Lors du téléchargement des contenus (pages ou fichiers), l'ensemble du contexte de ces téléchargements est conservé dans une base de données, dénommée la base du contexte, qui n'a pas été représentée sur la Figure 1.

Les documents suspects téléchargés au moyen des méthodes précédentes sont avantageusement sélectionnés par un premier filtrage pour déterminer s'ils méritent ou non d'être traités par la méthode de vérification des empreintes.

Les critères de sélection peuvent être de différentes natures et peuvent comprendre à titre d'exemples :

- le type de média (par exemple image),
- l'état du fichier (par exemple fichier corrompu),
- des informations internes à ce fichier (taille du contenu, et critère selon lequel par exemple une taille d'image trop petite, inférieure à 5x5 pixels ne présente pas d'intérêt pour la vérification par la technologie d'empreintes),
- des informations calculées à partir des informations précédentes (par exemple critère selon lequel un rapport hauteur sur largeur d'une image supérieure à 20 signifie qu'il s'agit d'un séparateur ou d'un élément de décor).

Les fichiers téléchargés et retenus à l'issue de l'étape de filtrage optionnelle décrite ci-dessus font l'objet d'un calcul d'empreintes dans le

module 105, selon la même technologie que celle utilisée pour le calcul d'empreintes originales effectué dans l'étape du module 101.

Des empreintes suspectes des documents suspects téléchargés et retenus peuvent ainsi être calculées selon des techniques décrites dans  
5 la demande de brevet français 2 863 080 précitée.

On notera que s'il est nécessaire d'utiliser, pour le calcul des empreintes suspectes, la même technologie que pour le calcul des empreintes originales, on peut utiliser une empreinte plus riche pour le document original de référence et une empreinte simplifiée pour le  
10 document suspect téléchargé. En effet, si l'on découvre qu'une partie de l'empreinte suspecte correspond à l'empreinte originale, cela sera suffisant pour déterminer qu'il y a une copie partielle et donc un plagiat.

Les empreintes suspectes calculées sont vérifiées par rapport aux empreintes originales et regroupées en classes par rapprochement  
15 des empreintes similaires. L'utilisation de caractéristiques formelles (titre, code de hash, identifiant de connexion,...) associées aux contenus permet d'étendre les regroupements déjà effectués à partir de la seule similarité d'empreintes.

Les empreintes suspectes sont stockées dans une base  
20 d'empreintes qui peut être par exemple combinée à la base d'empreintes 102 contenant les empreintes originales.

La vérification des empreintes suspectes et leur comparaison peut être effectuée par exemple selon les technologies décrites dans la demande de brevet FR 2 863 080 ou encore selon d'autres procédés  
25 comme par exemple en utilisant une distance de comparaison entre contenus.

Comme on l'a déjà indiqué précédemment, lors du téléchargement de contenus sous la forme de pages ou fichiers, l'ensemble du contexte de ces téléchargements est conservé dans une base de données  
30 110 dénommée la base du contexte.

Cette base de données 110 est exploitée dans le module 107 pour trouver une représentation sous forme de données formelles des contenus validés par l'étape de vérification du module 106.

Pour chaque contenu validé, on extrait un ensemble  
35 d'informations formelles sélectionnées qui sont préexistantes, ou que l'on calcule, telles que par exemple la taille, le code de hash, le titre,

l'identifiant de connexion d'utilisateur, les mots-clefs, le lieu de diffusion, le domaine du contenu,...

La nature de ces informations formelles peut être définie a priori par le système. Par exemple, dans le cas d'une fouille dans un contexte  
5 poste à poste, la taille et le code de hash sont deux éléments d'information permettant une identification quasi parfaite des contenus. Selon un autre exemple, dans la fouille de pages web sur un site dédié présentant des contenus proposés à la vente par un utilisateur donné, l'identifiant de cet utilisateur associé à une numérotation locale d'objet  
10 peut être une excellente identification de contenu.

La nature des informations formelles peut également être découverte grâce à un mécanisme d'apprentissage. Par exemple, un mécanisme du type réseau de neurones peut recevoir en entrée un vecteur agglomérant l'ensemble des informations formelles caractérisant le  
15 contenu, se voir imposer une valeur de sortie lors d'une phase d'apprentissage supervisée pour lui permettre de classer ce contenu d'après ces caractéristiques dans des classes prédéfinies (par exemple objets volés, recels, copies, contrefaçons,...). Cette pratique peut être réitérée jusqu'à ce que le mécanisme apprenne la relation entre certaines  
20 caractéristiques pour qu'il soit à même, lorsqu'on lui présente un nouveau contenu, d'en déduire dans quelle catégorie il doit être placé.

Les données formelles associées à un contenu suspect sont rangées dans une base de données 108 avec un identifiant permettant de retrouver ce contenu suspect et le contenu original auquel il correspond.

25 Un module 109 de réordonnement permanent est avantageusement associé à la base de données formelles de déclenchement 108.

Il est en effet intéressant que certains contenus soient retenus comme prioritaires par rapport à d'autres, du fait que ces contenus  
30 correspondent à des éléments plus particulièrement critiques pour différentes raisons qui permettent de déterminer des critères de criticité. On peut ainsi noter à titre d'exemples les critères de criticité suivants :

- criticité de la période : par exemple si un film est divulgué avant sa sortie en salle,
- 35 - criticité de la forme : par exemple s'il existe une version de grande qualité pouvant remplacer un DVD,

- danger du contenu : si des contenus sont prohibés, par exemple du fait de leur caractère pédophile,

- fréquence du contenu : s'il existe une variante très fortement diffusée.

5 Le réordonnement de la base de données formelles 108, à partir du module 109, comprend une sélection qui peut ainsi être effectuée par exemple à l'aide d'un processus faisant apparaître des priorités.

10 Chaque contenu est affecté d'une valeur en fonction du tableau des criticités, lequel tableau comprend des colonnes, dont chacune représente l'une des propriétés à prendre en considération, et des lignes dont chacune représente un contenu. A l'intersection des lignes et colonnes, un indice note un niveau de criticité par exemple entre 1 et 100. Un contenu est classé par le produit des différents indices le concernant.

15 D'autres procédés peuvent être utilisés pour effectuer cet ordonnancement qui peut se répéter en permanence, en fonction des nouvelles informations transmises à la base de données 108, certaines de ces informations provenant des modules d'intervention en ligne qui seront décrits plus loin.

20 D'une façon générale, chaque indice devant servir à une sélection peut être calculé automatiquement en fonction de la reconnaissance du contenu effectuée dans le module 106 de vérification et de classement, d'informations fournies lors de l'enregistrement des documents originaux, ainsi que de faits mesurés lors de l'intervention en

25 ligne.

A titre d'exemple, la fréquence du contenu est un fait mesuré : si le fichier a été vu plusieurs fois durant un intervalle de temps, sa fréquence augmente.

30 Le critère de danger du contenu provient de la reconnaissance de contenu : ainsi, un contenu pédophile est classé comme tel dans la base de données des documents originaux (base d'empreintes 102).

35 La criticité de la période peut provenir d'un mélange de plusieurs facteurs. Ainsi, la reconnaissance d'un film particulier est connue dans la base des documents originaux et la date de lancement de ce film est également connue dans cette base. Pour un jour donné, la détermination du fait que ce film ne sortira en salle que deux semaines



après ce jour donné signifie qu'il y a une criticité de période, ce film ne devant pas apparaître avant sa sortie en salle.

Le contenu étant classé dans la base de données formelles 108 par ordre de criticité, un seuil réglable permet de définir à partir de quelles valeurs de criticité un contenu doit être traité. Seules les données  
5 formelles des contenus sélectionnés par ce mécanisme seront transmises aux modules d'intervention en ligne qui vont maintenant être décrits.

Au moins un module d'intervention en ligne 201, 202, 203 est ainsi alimenté par intermittence, par exemple une fois par jour (mais cette  
10 fréquence peut être adaptée aux besoins et aux ressources et n'est pas nécessairement régulière) avec une copie au moins partielle de la base de données formelles de déclenchement, cette copie contenant des données formelles correspondant aux contenus alors classés comme prioritaires.

Un module d'intervention en ligne sur le réseau de transmission  
15 de données peut agir de manière à intercepter, bloquer, constater, analyser des contenus qui transitent sur des réseaux P2P ou qui sont publiés sur des sites web.

On voit sur la Figure 1 de façon schématique un module 201 d'interception en ligne qui permet d'assurer un blocage sélectif  
20 de contenus, avec également le cas échéant la possibilité d'assurer une comptabilisation 206 et/ou un stockage 205 d'informations bloquées.

Le module 202 d'interrogation en ligne permet de déclencher une alerte 207 en cas de détection de contenu suspect en réponse à une  
25 requête et peut également effectuer la comptabilisation 209 et/ou le stockage 208 des informations multimédia suspectes reconnues au moyen des données formelles associées à ces informations.

Le module 203 d'écoute en ligne permet de détecter de façon passive des contenus suspects identifiés au moyen des données formelles associées à ces contenus, et permet de la même manière de déclencher  
30 une alerte 217, et également le cas échéant d'effectuer une comptabilisation 219 et/ou un stockage 218 des informations suspectes reconnues.

On notera que le fait d'utiliser la base de données formelles 108, dupliquée au moins partiellement au niveau de chaque module  
35 d'intervention en ligne 201, 202, 203, au lieu de la base d'empreintes 102, permet d'accélérer fortement le traitement et de n'embarquer dans le

dispositif d'interception/interrogation/écoute qu'une faible partie des moyens techniques de l'ensemble du système, cette faible partie de moyens techniques pouvant par ailleurs être facilement adaptée pour prendre en compte des critères formels externes définis arbitrairement par les utilisateurs du système. Ainsi, par exemple, un utilisateur peut décider que seuls les paquets correspondant à des échanges d'un volume supérieur à un seuil doivent être traités, les autres n'étant pas considérés comme gênants.

La Figure 2 montre un exemple de réalisation d'un module 201 d'interception en ligne qui est placé sur un réseau de transmission de données pour faire transiter de façon conditionnelle et proportionnelle entre son entrée 249 et sa sortie 250 des paquets de données transmis sur le réseau. Le module 201 est également conçu pour pouvoir enregistrer des informations.

De façon plus particulière, le module 201 comprend un module 240 de stockage local d'au moins une partie des données formelles de la base de données formelles de déclenchement 108.

Un module tampon 241 permet de conserver de façon temporaire un paquet de données entrant. Les paquets issus du module tampon 241 sont avantageusement filtrés dans un module optionnel de filtrage 242 qui permet de présélectionner certains paquets à partir d'une règle de filtrage, par exemple pour effectuer un filtrage protocolaire.

Les paquets issus du module tampon 241 qui n'ont pas été éliminés au niveau du module de filtrage 242 sont fournis à un module 243 d'analyse et de comparaison entre les données issues du réseau à travers le module tampon 241 et les données stockées dans le module de stockage local.

Un module de déclenchement 244 réagit aux informations fournies par le module d'analyse 243 pour décider d'autoriser ou non la transmission du message issu du réseau, à travers le module 245 de transmission sélective activé par le module de déclenchement 244, vers la sortie 250 du module 201 reliée au réseau.

Au sein du module d'analyse, on procède à une comparaison d'une chaîne d'octets extraite du paquet de données analysé avec des chaînes de référence correspondant aux données formelles stockées dans le module 240 de stockage local.

Si une chaîne d'octets est reconnue, le module de déclenchement 244 envoie au module tampon 241 un signal pour effacer le contenu qui vient d'être traité et demander l'envoi du paquet suivant. Ce signal est confirmé en cas de transmission du message par le module  
5 245 de transmission sélective lorsqu'il y a eu accusé de réception de la bonne transmission de ce message.

Le module de déclenchement 244 permet également de commander le stockage éventuel des messages interceptés dans une mémoire 248, et de collecter sur une ligne 247 un certain nombre  
10 d'informations, notamment d'ordre statistique par exemple sur la nature des paquets en transit, les protocoles mis en jeu ou les contenus les plus fréquents. Ces informations peuvent avoir une influence sur la hiérarchisation des données formelles de la base de données formelles  
108. Aussi, de telles informations de nature statistique peuvent être  
15 renvoyées périodiquement (par exemple chaque semaine ou quinzaine) ou lorsqu'elles sont suffisantes en nombre vers la base de données formelles 108.

La Figure 3 montre un exemple de module 202 d'interrogation en ligne.

20 Le module 202 permet d'interroger ou d'explorer le contenu d'un serveur web ou poste à poste à partir de requêtes élaborées dans un module de requête 271 à partir des données correspondant aux documents originaux, ou par une alimentation externe spécifique.

Les données collectées sur le réseau par le module de requête  
25 271 en réponse aux requêtes formulées sont transmises le cas échéant à travers un module de filtrage 272 analogue au module de filtrage 242 vers un module d'analyse 273 qui opère une comparaison entre ces données collectives et les données formelles stockées dans le module 270 de stockage local d'au moins une partie de la base de données formelles de  
30 déclenchement 108.

Un module de déclenchement 274 réagit aux résultats des comparaisons effectuées dans le module d'analyse 273 pour selon le cas commander le déclenchement d'une alerte 276, le stockage dans une mémoire 278 des données collectées, l'extraction de données statistiques  
35 pouvant être renvoyées par une ligne 277 vers la base de données

formelles 108, ou encore commander de ne rien faire du tout (action 275 de la Figure 3).

5 A titre d'illustration, si l'on considère par exemple la détection de recel en ligne, on peut détecter les contenus en situation de recel par reconnaissance des données ou critères formels extraits de la base de données formelles 108. Les données formelles constituent un ensemble d'informations corrélées pour produire une décision et peuvent dans le cas considéré comprendre par exemple un identifiant d'utilisateur, un nom de pays d'origine, un prix.

10 On notera que l'alerte déclenchée au niveau du module d'émission d'alerte 276 peut prendre diverses formes comme par exemple l'envoi de messages par courriel ou par SMS, l'affichage d'informations sur un site en ligne, ou encore l'utilisation d'un outil spécial de vigilance contre la contrefaçon, comme par exemple un mécanisme de verrouillage ou  
15 d'invalidation d'une offre.

Les données statistiques extraites peuvent être envoyées vers une base de données spécifique pouvant donner lieu à diverses applications comme par exemple le calcul de la répartition de droits perçus entre ayants droit.

20 Les informations stockées dans la mémoire 278 (comme dans la mémoire 248) peuvent être par exemple réunies autour d'un même fournisseur de contenu pour permettre de réaliser un inventaire des actions concernant ce diffuseur. Ces informations peuvent être stockées et horodatées au moyen d'un service automatisé d'archivage de documents  
25 pour une action différée.

La Figure 4 montre un exemple de module 203 d'écoute en ligne. Un tel module peut comprendre des modules ou éléments 290 et 292 à 298 qui sont tout à fait similaires aux modules ou éléments 270 et 272 à 278 précédemment décrits en référence à la Figure 3. Ces modules  
30 ne seront donc pas décrits à nouveau.

Le module 203 d'écoute en ligne, qui constitue un module entièrement passif, comprend en outre un serveur mandataire 291 d'écoute de requêtes de clients et de recopie des requêtes et des données collectées en réponse aux requêtes.

35 Le serveur mandataire 291, qui peut être utilisé dans un contexte P2P ou un contexte web, assure des transmissions transparentes

entre client et serveur mais envoie en entrée 299 du module d'analyse 293, ou du module de filtrage 292, s'il existe, une copie des requêtes de clients et des réponses à ces requêtes, qui ont transité par ce serveur mandataire 291.

5            On notera que le procédé et le système de repérage et de filtrage d'informations multimédia par séparation en données formelles peut présenter diverses variantes.

          En particulier, au niveau du module 100 de surveillance hors ligne, il peut être avantageux de modifier régulièrement l'adresse IP à  
10 partir de laquelle on procède à une fouille sur le réseau, et un téléchargement, afin de rendre les échanges anonymes.

          On décrira maintenant en référence à la Figure 5 un exemple particulier d'application de la présente invention au repérage et au filtrage des annonces de produits contrefaits sur des places de marché  
15 électronique.

          Les places de marché électronique permettent une fragmentation de la diffusion de produits contrefaits, ceux-ci pouvant être proposés à la vente en petits lots par un même revendeur qui est enregistré sous différentes identités d'emprunt.

20            Le système illustré sur la Figure 5 permet notamment de remédier à cet inconvénient et de rendre repérable un tel comportement de vente de produits contrefaits par petits lots.

          Sur la Figure 5, la référence 10 désigne un module de surveillance hors ligne qui pour l'essentiel est conforme au module de  
25 surveillance 100 de la Figure 1.

          Les documents originaux 11A peuvent être constitués par exemple par une marque, un dessin, un modèle, une brochure susceptibles d'être contrefaits.

          Le module 11 assure le calcul des empreintes originales des  
30 documents originaux 11A comme indiqué plus haut en référence à la Figure 1. Ces empreintes originales sont stockées dans une base d'empreintes 12 à laquelle a accès un module de fouille 13 qui procède sur le réseau Internet (web) 19 à une fouille de surveillance portant sur un nombre important de documents, tels que des brochures et sur les  
35 informations qu'elles contiennent.

Le module 13 de fouille des annonces ou documents analogues coopère avec un module 14 de téléchargement des informations collectées par le module de fouille 13.

Un module 15 de calcul d'empreintes suspectes permet de  
5 calculer les empreintes des documents suspects collectés et téléchargés. Ces empreintes suspectes sont intégrées dans une base d'empreintes qui peut être combinée avec la base d'empreintes 12 des empreintes originales. La base d'empreintes 12 peut ainsi regrouper l'ensemble des  
10 empreintes originales et des empreintes suspectes en procédant par exemple à des regroupements par utilisateur virtuel.

Le module 16 utilise les empreintes suspectes et les empreintes originales pour procéder à des comparaisons et vérifications entre ces empreintes puis à un regroupement des annonces concernées par ces  
15 empreintes pour les organiser en classes d'équivalence par rapprochement des empreintes similaires.

Les classes d'équivalence permettent ensuite au moyen d'une analyse transitive de déduire les caractéristiques formelles des annonces (par exemple identifiant d'utilisateur, lieu de diffusion, éléments factuels  
20 du texte des brochures ou mots-clefs) correspondant à des cas de contrefaçons probables. Cette tâche est accomplie par un module de production de données formelles qui sur la Figure 5 est combiné avec le module 16. Les données formelles sont stockées dans une base de données formelles 18 qui constitue ainsi une base des identifiants factuels de contenus diffusés illégalement, avec un classement hiérarchique par  
25 ordre d'importance comme décrit précédemment en référence à la Figure 1.

Un module 21 associé à la base de données formelles 18 assure la diffusion régulière vers un module 20 d'intervention en ligne, d'une partie de la base de données formelles 18 pour former une réplique locale  
30 23 de cette base de données formelles.

Le module 20 d'intervention en ligne est actif en permanence et détecte automatiquement les nouvelles annonces au niveau du module  
35 24. Ces nouvelles annonces, dans un module d'analyse 25, font l'objet d'une vérification des données formelles qu'elles comportent, par comparaison avec les données formelles contenues dans la base de données formelles 23. Un module de déclenchement 26 décide ensuite, en

fonction du résultat de l'analyse, de retenir une nouvelle annonce détectée sur le réseau, si cette nouvelle annonce comprend un nombre suffisant de données formelles qui correspondent aux données formelles stockées dans la base 23. Sinon, l'annonce continue son chemin sur le réseau sur la ligne  
5 28.

Lorsqu'une annonce a été retenue, elle peut être bloquée, comme indiqué par le repère 27, ou faire simplement l'objet d'une alerte. L'alerte peut consister par exemple en l'envoi d'un avertissement (émission par le module 29 commandé par le module 16 de vérification et  
10 classement).

Le module de surveillance 10 et la base de données formelles 18 travaillent hors ligne sur les annonces déjà publiées ainsi que sur l'historique des annonces, tandis que le module 20 d'intervention en ligne qui est actif en permanence détecte automatiquement les nouvelles  
15 annonces et les accepte ou les rejette en conséquence immédiatement.

Un module de réordonnement permanent peut être associé à la base de données formelles 18, comme décrit en référence à la Figure 1.

Le module 21 procède à une diffusion régulière, vers la réplique locale 23, des données formelles devenues hiérarchiquement plus  
20 importantes.

La Figure 6 décrit une application particulière de l'invention au repérage et au filtrage de contenus prohibés sur des réseaux poste à poste.

Les protocoles d'échanges de fichiers poste à poste permettent  
25 à des utilisateurs ne se connaissant pas de partager des fichiers au moyen d'informations déclaratives sur les contenus de ce fichier. Un utilisateur (télépartageur ou serveur) met à disposition un contenu sur le réseau à l'adresse de l'utilisateur. Quelqu'un à la recherche d'un contenu de ce type interroge l'un de ces serveurs, trouve l'information et envoie une requête  
30 de téléchargement à l'adresse du premier intervenant. Le partage de fichier commence alors.

Ces échanges se font dans un très grand nombre de cas en marge de la légalité. Les contenus sur lesquels s'applique un droit d'auteur ou un droit voisin sont rapidement diffusés d'intervenants à intervenants,  
35 avec une propagation exponentielle, sans respect de la législation sur les droits d'auteur.

Le système selon l'invention permet de remédier à ce problème en effectuant un filtrage sur les contenus transitant par un point de passage permettant de déterminer au sein d'un échange P2P si le contenu échangé est partagé dans des conditions légales ou dans des conditions  
5 qui enfreignent les lois sur le droit d'auteur.

Cette détection de contenu peut difficilement être faite sur une étude détaillée du contenu de par les contraintes d'exploitation du point d'interception. En effet, les débits des points de passage pouvant être exploités tels qu'un serveur d'accès à large bande (BAS) d'un opérateur ou  
10 un récepteur (LNR) d'un fournisseur d'accès, sont dimensionnés sur des débits qui sont souvent de l'ordre du gigabit par seconde. De tels débits rendent difficile la constitution de solutions de détection intégrant un calcul d'empreintes à la volée sur les paquets de données échangés, suivi d'une reconnaissance de ce contenu dans une base d'empreintes de  
15 documents originaux, représentative des droits d'auteur que l'on souhaite protéger et qui peut correspondre à quelques centaines de milliers de documents.

Selon l'invention grâce à la séparation entre la reconnaissance intelligente des contenus au moyen d'empreintes dans un module de  
20 surveillance 30, et la caractérisation des contenus au moyen de données formelles qui permettent une intervention en ligne en temps réel dans des modules 40 d'intervention en ligne, on peut effectuer un repérage et un filtrage de contenus prohibés de façon simple et fiable sur des réseaux P2P malgré la grande quantité de documents concernés.

Il est avantageux de choisir comme données formelles des codes de hash protocolaires. Ces codes de hash sont des signatures calculées au moyen de fonctions de hachage à sens unique fournies par les protocoles d'échange P2P. Ces codes de hash servent dans ces protocoles à s'assurer de l'intégrité, de la validité et de la compatibilité des  
30 morceaux de contenu échangés par les intervenants. Ces codes de hash sont calculés sur les logiciels clients de l'échange poste à poste et sont inclus dans les échanges à la fois dans les requêtes et dans les réponses.

Ces codes de hash sont par ailleurs placés dans les premiers blocs d'entête des paquets échangés ce qui facilite leur détection.

35 Sur la Figure 6, le module 31 assure le calcul des empreintes originales à partir des documents originaux à protéger 31A. Ces



empreintes originales sont stockées dans une base d'empreintes originales 32 à laquelle a accès un module 33 de fouille des protocoles P2P disponibles sur le réseau 39.

Le module de fouille 33 recherche et observe les contenus P2P  
5 proposés à l'échange et coopère avec un module de téléchargement 34  
qui transfère les contenus collectés à un module 35 de calcul d'empreintes  
suspectes. Le module 36 de vérification et classement regroupe au moyen  
des empreintes calculées les contenus téléchargés et les codes de hash  
correspondants et les caractérise par rapport aux contenus originaux  
10 fournis par les ayants droit.

Le module 36 incorpore également un module de production de  
données formelles, qui procède à un tri des codes de hash les plus  
intéressants (ceux qui représentent les échanges les plus dangereux) et  
fournit ces codes de hash constituant des données formelles à une base  
15 de données formelles 38 qui inclut ainsi les codes de hash des contenus  
diffusés illégalement, avec leur classement hiérarchique.

Un module 41 assure la diffusion régulière (par exemple  
quotidienne) des meilleurs données formelles de la base de données  
formelles 38, c'est-à-dire les données formelles hiérarchiquement les plus  
20 importantes, à des répliques locales 43 d'au moins une partie de la base  
de données formelles 38.

Dans chaque module 40 d'intervention en ligne sur le réseau, en  
un point d'écoute 42, on trouve un équipement 44 assurant le captage des  
données du réseau et la fonction de module tampon pour extraire en  
25 temps réel les données formelles comprenant les codes de hash  
protocollaires des paquets de données P2P.

Le module 30 qui procède aux calculs d'empreintes fouille ou  
observe les réseaux P2P sans contrainte de temps tandis que les modules  
40 d'intervention en ligne procèdent à une détection de données formelles  
30 (codes de hash) en temps réel sur les paquets de données en transit au  
point de passage sélectionné 42.

Au sein d'un module 40, un module d'analyse 45 coopère avec  
la réplique locale 43 de la base de données formelles 38 et avec  
l'équipement 44 captant les données du réseau P2P dans un module  
35 tampon, pour détecter les entêtes des paquets de données et procéder à

une analyse et vérification du code de hash par rapport aux codes de hash déjà stockés dans la réplique locale 43.

5 Selon le résultat de cette analyse, un module de déclenchement 46 décide de bloquer un paquet de données considéré comme ayant un contenu illégal (repère 47) ou de le laisser ressortir sur le réseau (repère 48).

10 Naturellement, dans l'exemple décrit ci-dessus de façon simplifiée, comme dans le cas général décrit en référence à la Figure 1, le module d'intervention sur le réseau, qui est constitué par un module d'interception en ligne 60, peut être remplacé ou complété si on le souhaite par un module d'interrogation en ligne ou un module d'écoute en ligne.

## REVENDICATIONS

1. Procédé de repérage et de filtrage d'informations multimédia sur un réseau de transmission de données, caractérisé en ce qu'il comprend les étapes suivantes :
- a) surveiller hors ligne des informations multimédia par rapport à des informations multimédia de référence, avec les étapes suivantes :
    - a1) calculer des empreintes originales des informations multimédia de référence,
    - a2) stocker les empreintes originales de référence calculées dans une base d'empreintes,
    - a3) fouiller des informations multimédia sur le réseau et télécharger des informations suspectes,
    - a4) calculer des empreintes suspectes des informations multimédia suspectes,
    - a5) vérifier les empreintes suspectes par rapport aux empreintes originales et regrouper les empreintes suspectes en classes par rapprochement des empreintes similaires,
    - a6) produire des données formelles avec une affectation de priorité par classe d'empreintes et stocker les données formelles dans une base de données formelles de déclenchement,
    - a7) alimenter par intermittence au moins un module d'intervention en ligne sur le réseau avec une copie au moins partielle de la base de données formelles de déclenchement,
  - b) effectuer au moins l'une des opérations suivantes à l'aide dudit module d'intervention en ligne :
    - b1) intercepter en ligne des informations multimédia reconnues au moyen des données formelles présentes dans la base de données formelles de déclenchement et décider soit d'autoriser le passage, soit de provoquer le blocage des informations multimédia reconnues,
    - b2) interroger en ligne des informations multimédia reconnues au moyen des données formelles présentes dans la base de données formelles de déclenchement et procéder au moins à

une comptabilisation ou à un stockage des informations multimédia reconnues, ou à un déclenchement d'alerte lors de la reconnaissance des informations multimédia,

5 b3) écouter en ligne des informations multimédia reconnues au moyen des données formelles présentes dans la base de données formelles de déclenchement et procéder au moins à une comptabilisation ou à un stockage des informations multimédia reconnues, ou à un déclenchement d'alerte lors de la reconnaissance des informations multimédia.

10

2. Procédé selon la revendication 1, caractérisé en ce qu'on procède de façon périodique à un tri et un ordonnancement des données formelles de déclenchement de la base de données formelles, en sélectionnant les données formelles les plus importantes en fonction d'au moins un critère de priorité.

15

3. Procédé selon la revendication 1 ou la revendication 2, caractérisé en ce que, lors d'une opération d'interception en ligne d'écoute en ligne ou d'interrogation en ligne, on procède de façon périodique à une mise à jour des données formelles stockées dans la base de données formelles de déclenchement, à partir de données statistiques obtenues lors de l'opération d'interception en ligne, d'écoute en ligne ou d'interrogation en ligne.

20

4. Procédé selon l'une quelconque des revendications 1 à 3, caractérisé en ce que, après l'étape de fouille des informations multimédia sur le réseau et le téléchargement des informations suspectes, on procède à un filtrage des informations multimédia suspectes à l'aide d'au moins un entête de sélection prédéterminé, et on ne procède au calcul des empreintes suspectes que pour les informations multimédia suspectes satisfaisant ledit critère de sélection prédéterminé.

25

30

5. Procédé selon la revendication 4, caractérisé en ce que ledit critère de sélection prédéterminé comprend au moins l'un des éléments de sélection suivants pour un fichier contenant des informations multimédia

35

suspectes : le type de fichier selon la nature du média qu'il comporte, l'état de corruption du fichier, la taille du contenu du fichier.

5 6. Procédé selon l'une quelconque des revendications 1 à 5, caractérisé en ce que l'on calcule des empreintes originales des informations multimédia de référence et des empreintes suspectes des informations multimédia suspectes selon le même procédé, mais on détermine des empreintes suspectes présentant des caractéristiques simplifiées par rapport à celles des empreintes originales.

10

7. Procédé selon l'une quelconque des revendications 1 à 6, caractérisé en ce que l'on modifie régulièrement l'adresse IP à partir de laquelle on procède à une fouille sur le réseau et un téléchargement afin de créer une anonymisation des échanges.

15

8. Procédé selon l'une quelconque des revendications 1 à 7, caractérisé en ce que pour réaliser l'interception en ligne des informations multimédia, on fait transiter les paquets de données présents sur le réseau de façon conditionnelle dans un module d'interception comprenant un étage tampon pour conserver de façon temporaire un paquet de données entrant, un étage d'analyse d'un paquet de données et un étage de déclenchement pour autoriser la transmission du paquet de données analysé ou décider de son rejet, et commander ensuite l'effacement du paquet dans l'étage tampon et l'introduction d'un paquet suivant dans l'étage d'analyse.

20

9. Procédé selon la revendication 8, caractérisé en ce que dans le module d'interception, on procède à un filtrage préalable des paquets issus de l'étage tampon avant leur introduction dans l'étage d'analyse.

25

10. Procédé selon la revendication 8 ou la revendication 9, caractérisé en ce que dans le module d'interception, on utilise l'étage de déclenchement pour enregistrer en outre des données statistiques concernant les paquets rejetés ou transmis.

30

35

11. Procédé selon l'une quelconque des revendications 1 à 7, caractérisé en ce que pour réaliser l'interrogation en ligne des informations multimédia, on procède à une interrogation ou une exploration du contenu d'un serveur web ou poste à poste à partir de requêtes, on procède à une comparaison des données collectées en réponse à ces requêtes avec celles de la base de données formelles de déclenchement et, en fonction du résultat de la comparaison, on déclenche une alerte, on collecte des informations ou on s'abstient d'intervenir.

10

12. Procédé selon l'une quelconque des revendications 1 à 7, caractérisé en ce que pour réaliser l'écoute en ligne des informations multimédia, on procède au sein d'un serveur mandataire d'une part à l'écoute de requêtes de clients et à la recopie de ces requêtes et des données collectées en réponse à ces requêtes, et d'autre part à la transmission transparente de données entre client et serveur, on procède à une comparaison des données collectées recopiées avec celles de la base de données formelles de déclenchement et en fonction du résultat de la comparaison, on déclenche une alerte, on collecte des informations ou on s'abstient d'intervenir.

20

13. Procédé selon la revendication 11 ou la revendication 12, caractérisé en ce qu'on procède à un filtrage préalable des données collectées avant d'effectuer leur comparaison avec celles de la base de données formelles de déclenchement.

25

14. Procédé selon l'une quelconque des revendications 1 à 13, caractérisé en ce que l'étape consistant à fouiller des informations multimédia sur le réseau et télécharger des informations suspectes est effectuée sur des contenus poste à poste proposés à l'échange, en ce que les données formelles comprennent des codes de hash et en ce que l'interception ou l'écoute s'effectue en un point d'écoute du réseau poste à poste par extraction en temps réel des codes de hash des paquets de données d'échanges poste à poste.

35

15. Système de repérage et de filtrage d'informations multimédia sur un réseau, caractérisé en ce qu'il comprend :

- un module (100) de surveillance hors ligne des informations multimédia par rapport à des informations multimédia de référence, lequel  
5 module de surveillance hors ligne comprend au moins :
  - un module (101) de calcul d'empreintes originales des informations multimédia de référence,
  - un module (102) de stockage des empreintes originales de  
10 référence calculées,
    - un module (103) de fouille des informations multimédia sur le réseau,
    - un module (104) de téléchargement des informations suspectes détectées,
    - un module (105) de calcul des empreintes suspectes des  
15 informations multimédia suspectes téléchargées,
      - un module (102) de stockage des empreintes suspectes calculées,
      - un module (106) de vérification et de regroupement des empreintes suspectes en classes,  
20
        - un module (107) de production de données formelles avec une affectation de priorité par classes d'empreintes, et
        - un module (108) de stockage des caractéristiques formelles constituant une base de données formelles de déclenchement,  
25 et au moins l'un des modules suivants d'intervention en ligne sur le réseau :
          - a) un module d'interception en ligne (201) comprenant au moins
            - un module (240) de stockage local d'au moins une partie  
30 de la base de données formelles de déclenchement,
              - un module tampon (241),
              - un module d'analyse (243) et de comparaison entre les données issues du module tampon (241) et les données stockées dans le module de stockage local (200),
              - un module de déclenchement (244) réagissant aux  
35 informations fournies par le module d'analyse (243), et

- un module (245) de transmission sélective des informations multimédia reconnues, activé par le module de déclenchement (244),
- b) un module d'interrogation en ligne (202) comprenant au moins :
  - un module (270) de stockage local d'au moins une partie de la base de données formelles de déclenchement,
  - un module de requête (271) fournissant des données collectées en réponse à des requêtes,
  - un module d'analyse (273) et de comparaison entre lesdites données collectées en réponse et les données stockées dans le module de stockage local (270),
  - un module de déclenchement (274) réagissant aux informations fournies par le module d'analyse (273),
  - un module d'émission d'une alerte (276), de comptabilisation (277) ou de stockage (278) des informations multimédia reconnues, activé par le module de déclenchement (274),
- c) un module d'écoute en ligne (203) comprenant au moins :
  - un module (290) de stockage local d'au moins une partie de la base de données formelles de déclenchement,
  - un serveur mandataire (291) d'écoute de requêtes de clients et de recopie des requêtes et des données collectées en réponse aux requêtes,
  - un module d'analyse (293) et de comparaison entre lesdites données collectées en réponse et les données stockées dans le module de stockage local (290),
  - un module de déclenchement (294) réagissant aux informations fournies par le module d'analyse (293),
  - un module d'émission d'une alerte (296) de comptabilisation (297) ou de stockage (298) des informations multimédia reconnues, activé par le module de déclenchement (294).

16. Système selon la revendication 15, caractérisé en ce que le module d'interception en ligne (201) comprend en outre un module d'émission d'une alerte, de comptabilisation (247) ou de stockage (248)



des informations multimédia reconnues, activé par le module de déclenchement.

5           17. Système selon la revendication 15 ou la revendication 16, caractérisé en ce que le module de surveillance hors ligne comprend en outre un module (109) de réordonnancement périodique des données formelles de déclenchement de la base de données formelles.

10           18. Système selon l'une quelconque des revendications 15 à 17, caractérisé en ce que le module d'interception en ligne (201), le module d'interrogation en ligne (202) et le module d'écoute en ligne (203) comprennent en outre chacun un module de filtrage (242 ; 272 ; 292) disposé en entrée du module d'analyse.

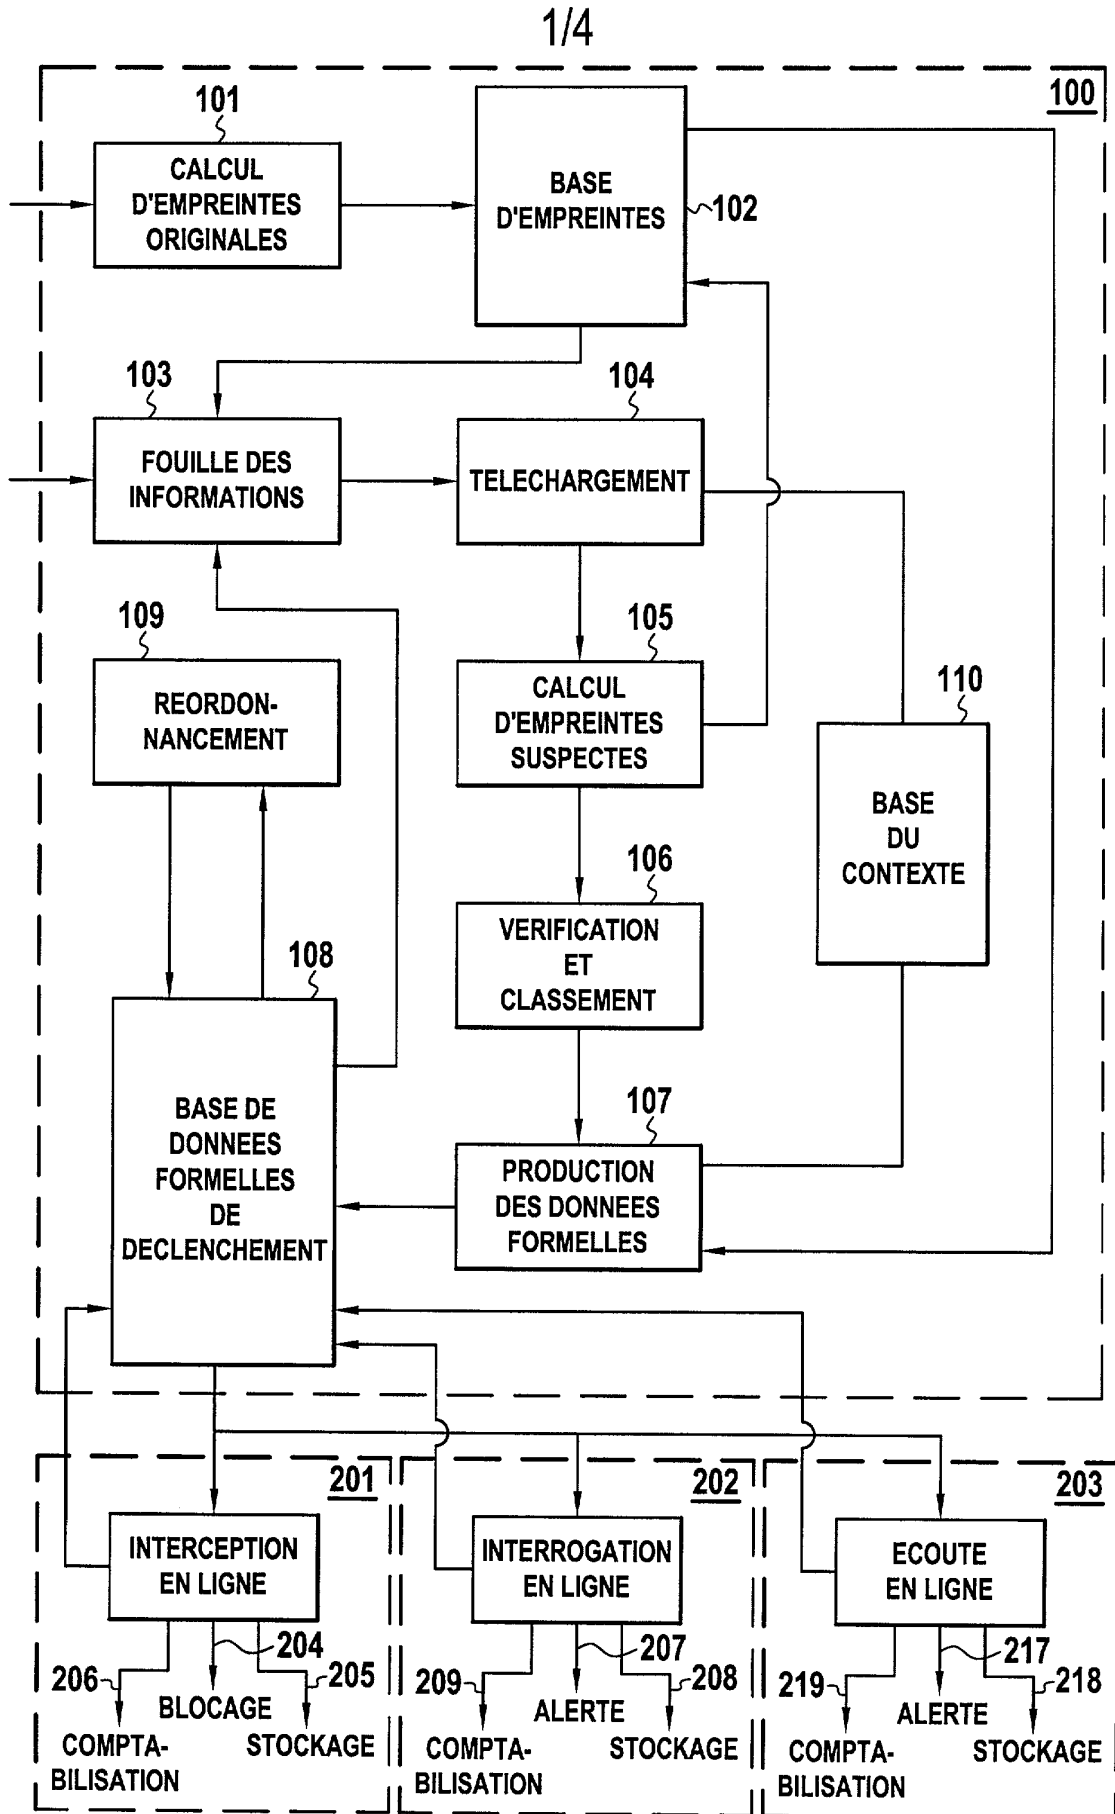


FIG. 1

2/4

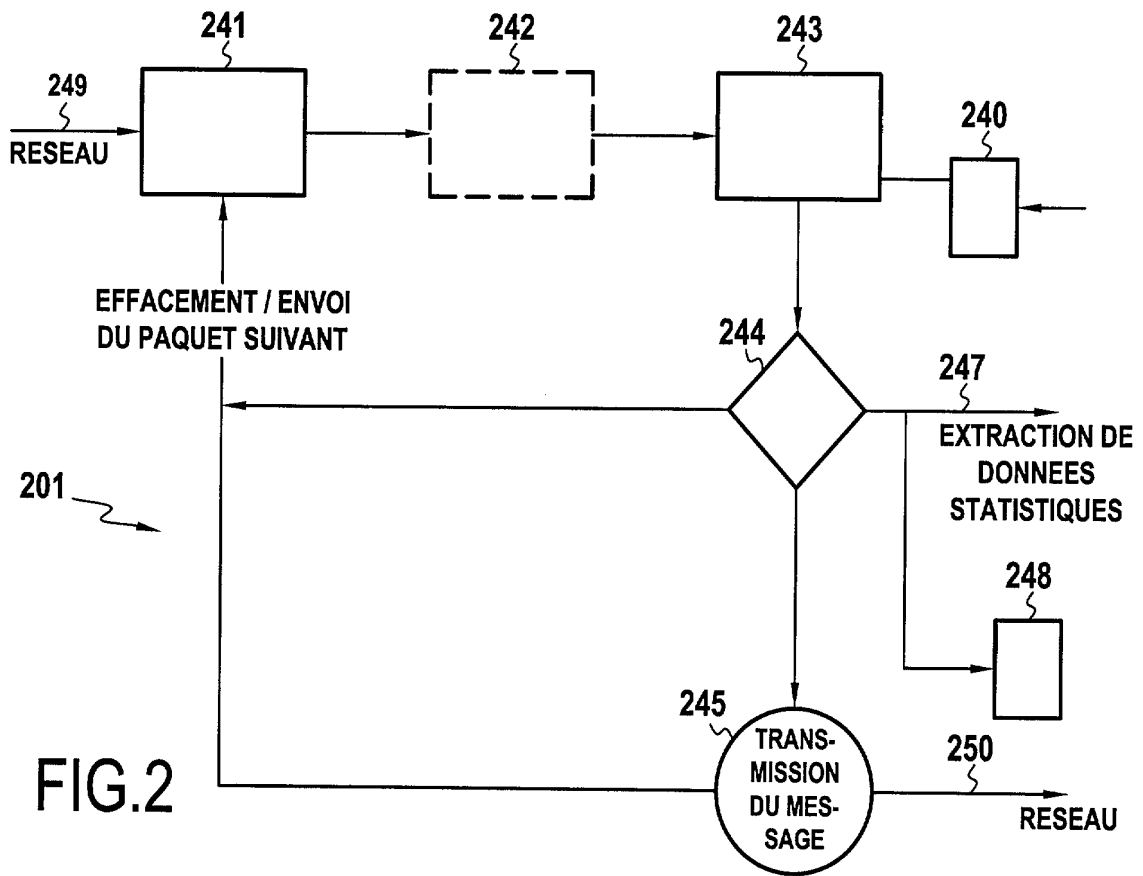


FIG. 2

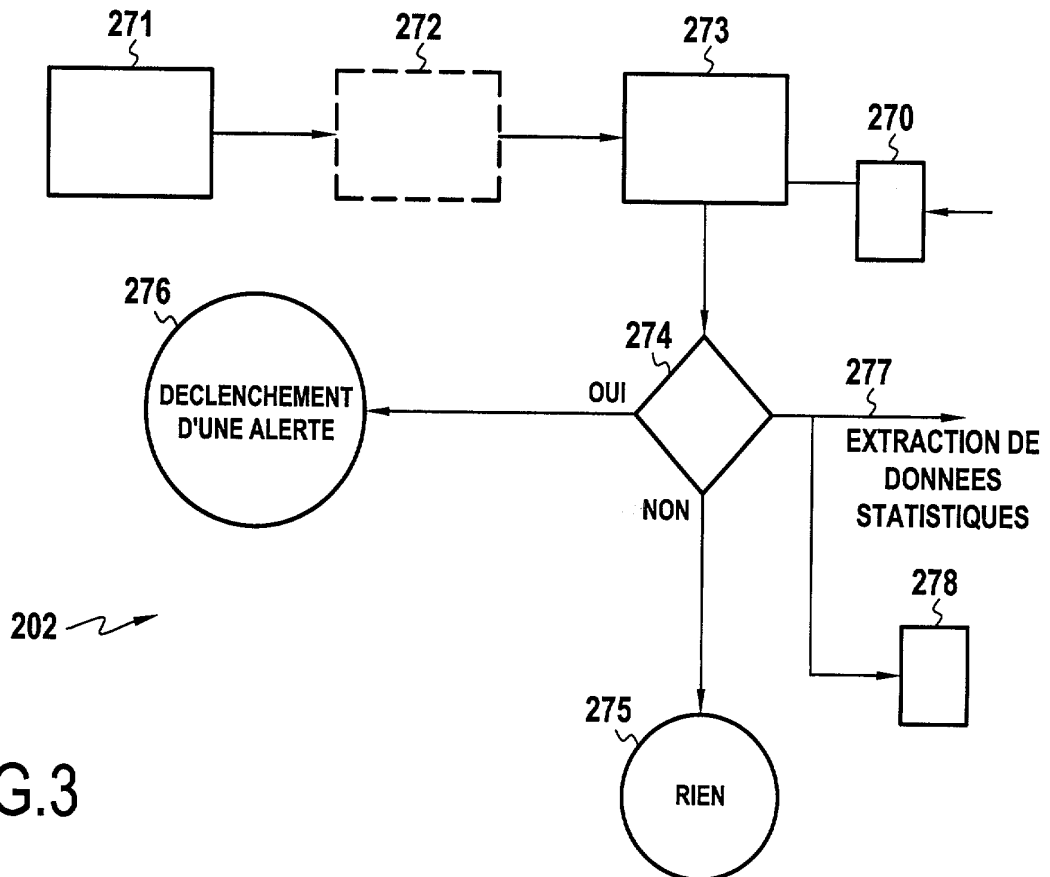
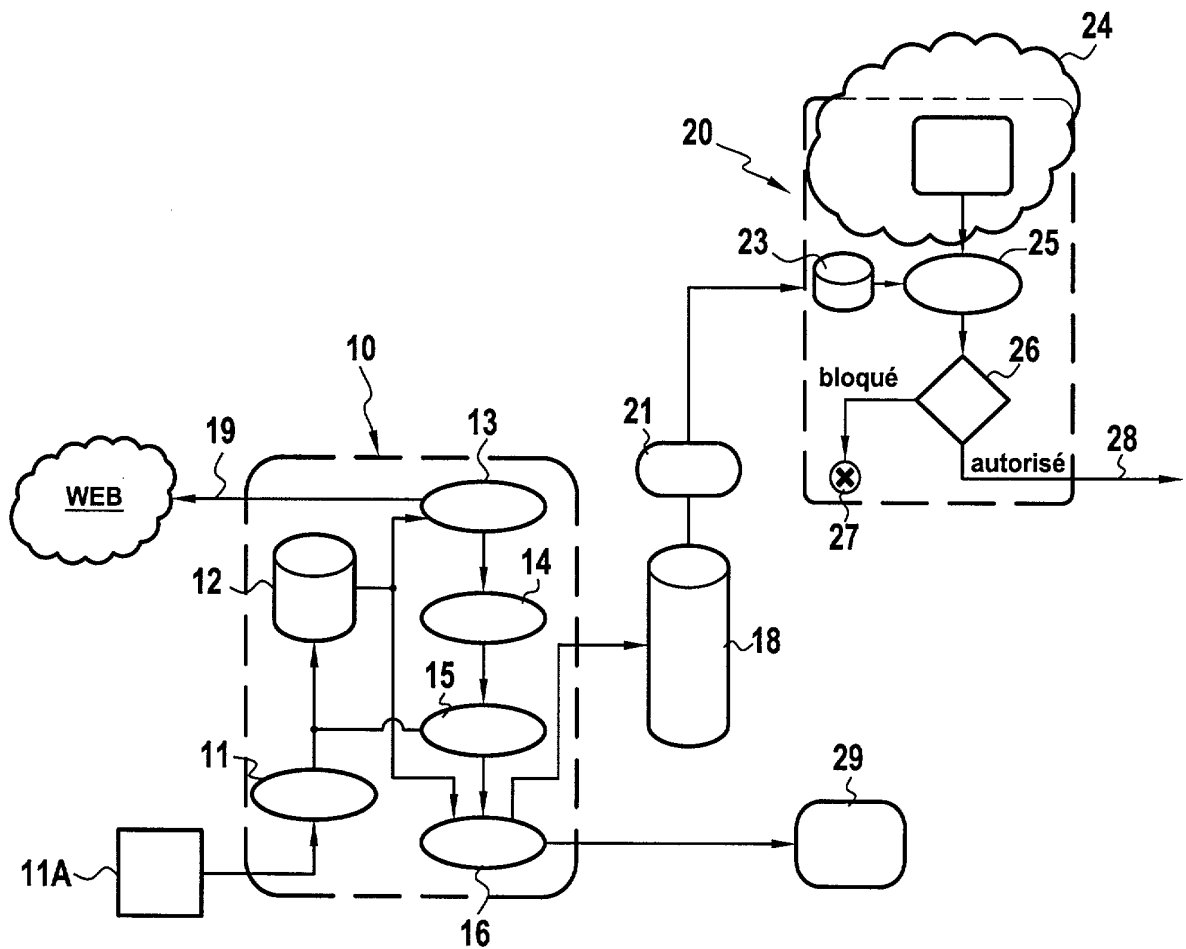
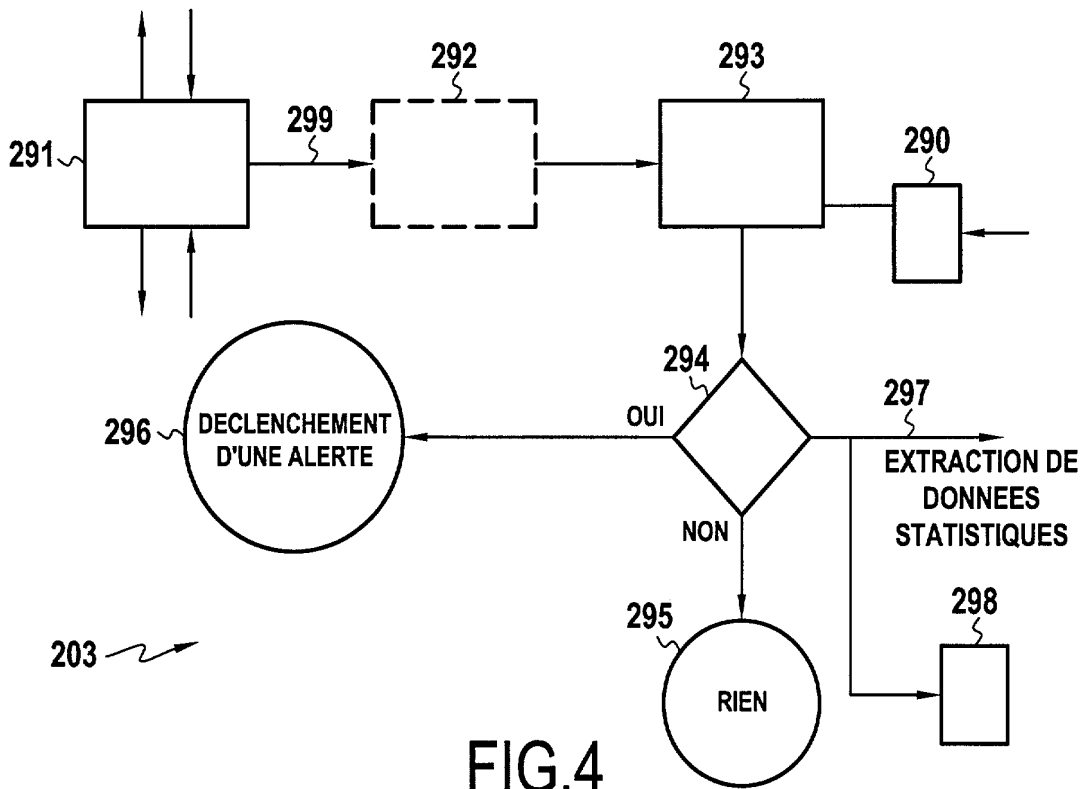


FIG. 3

3/4



4/4

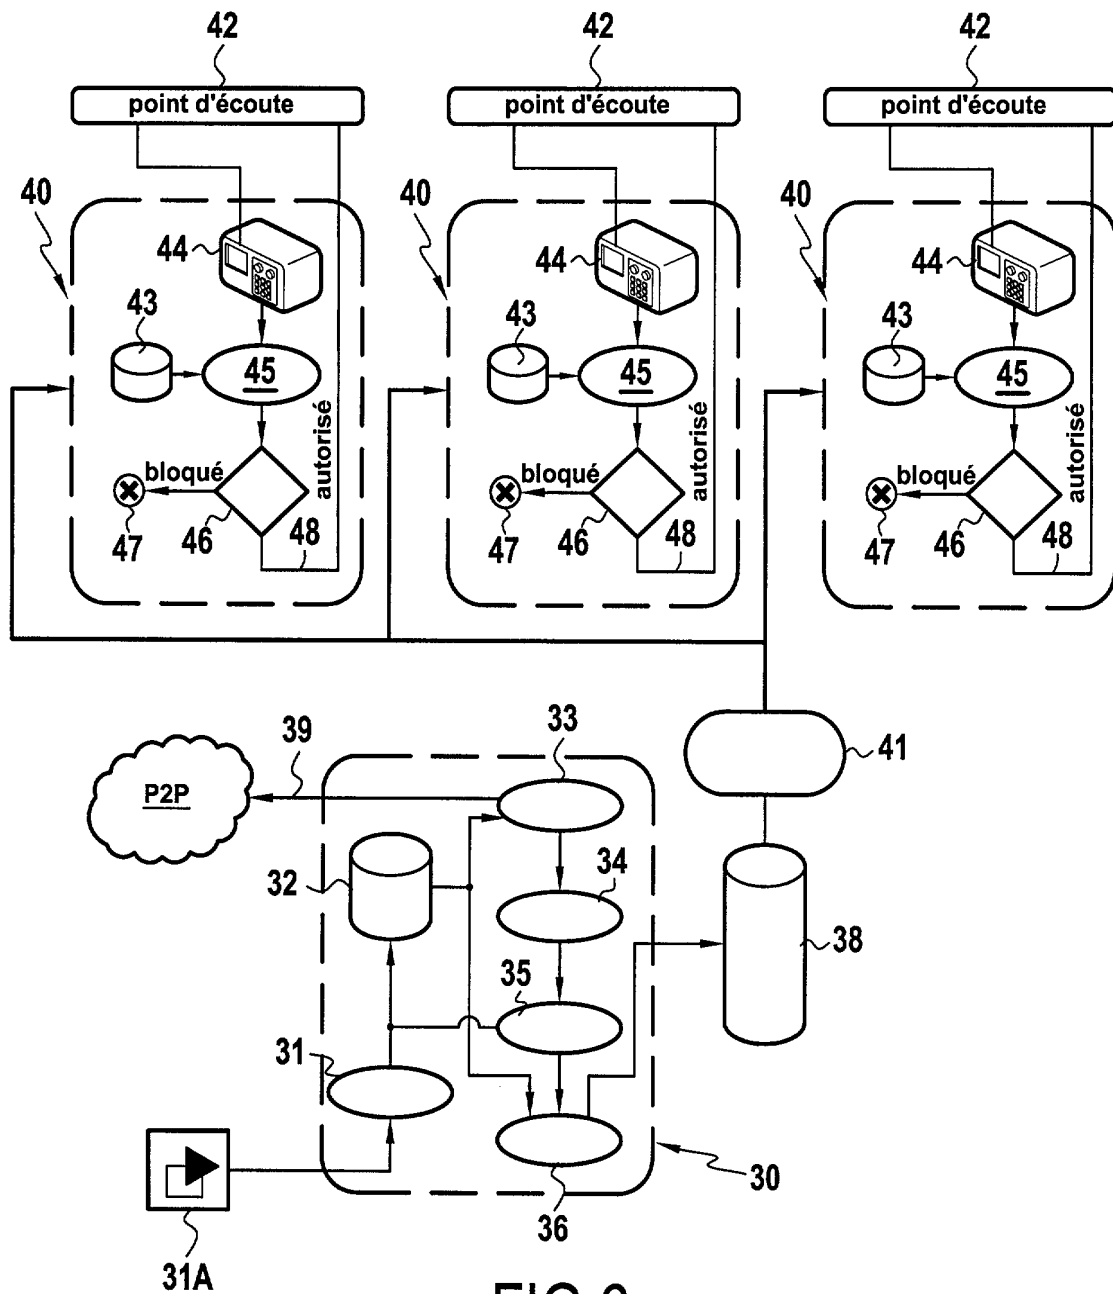


FIG. 6



**RAPPORT DE RECHERCHE  
PRÉLIMINAIRE**

établi sur la base des dernières revendications  
déposées avant le commencement de la recherche

N° d'enregistrement  
national

FA 667775  
FR 0506089

DOCUMENTS CONSIDÉRÉS COMME PERTINENTS		Revendication(s) concernée(s)	Classement attribué à l'invention par l'INPI
Catégorie	Citation du document avec indication, en cas de besoin, des parties pertinentes		
X	A. BRUGIDOU, G. KAHN: "CHARTRE POUR LE DEVELOPPEMENT DE L'OFFRE LEGALE DE MUSIQUE EN LIGNE, LE RESPECT DE LA PROPRIETE INTELLECTUELLE ET LA LUTTE CONTRE LA PIRATERIE NUMERIQUE - ETUDE DES SOLUTIONS DE FILTRAGE DES ECHANGES DE MUSIQUE SUR INTERNET DANS LE DOMAINE DU PEER-TO-PEER RAPPORT D'ETUDE" MINISTÈRE DÉLÉGUÉ À L'ENSEIGNEMENT SUPÉRIEUR ET À LA RECHERCHE, [Online] 9 mars 2005 (2005-03-09), XP002372239 Extrait de l'Internet: URL:http://www.espace.gouv.fr/rapport/piraterienumerique.pdf> [extrait le 2006-03-14] Section 3.5 and subsection -----	1-18	H04L12/26 G06F12/14 G06F17/30
X	WO 02/082271 A (AUDIBLE MAGIC CORPORATION) 17 octobre 2002 (2002-10-17) * abrégé * * page 6, ligne 25 - page 24, ligne 11 * * figures 1-7 * -----	1-18	DOMAINES TECHNIQUES RECHERCHÉS (IPC)
A	ADVESTIGO: "Services adVigilante - Description des services de surveillance et contrôle des contenus" ONLINE PUBLICATION, [Online] décembre 2003 (2003-12), XP002372240 Extrait de l'Internet: URL:http://www.ddm.gouv.fr/pdf/advestigo_090204.pdf> [extrait le 2006-03-15] * le document en entier * -----	1-18	G06F H04L
A	WO 03/067459 A (AUDIBLE MAGIC CORPORATION) 14 août 2003 (2003-08-14) * abrégé * ----- -/--	1-18	
Date d'achèvement de la recherche		Examineur	
15 mars 2006		Bertolissi, E	
<p>CATÉGORIE DES DOCUMENTS CITÉS</p> <p>X : particulièrement pertinent à lui seul Y : particulièrement pertinent en combinaison avec un autre document de la même catégorie A : arrière-plan technologique O : divulgation non-écrite P : document intercalaire</p>		<p>T : théorie ou principe à la base de l'invention E : document de brevet bénéficiant d'une date antérieure à la date de dépôt et qui n'a été publié qu'à cette date de dépôt ou qu'à une date postérieure. D : cité dans la demande L : cité pour d'autres raisons ..... &amp; : membre de la même famille, document correspondant</p>	

3  
EPO FORM 1503 12.99 (P04C14)



**RAPPORT DE RECHERCHE  
PRÉLIMINAIRE**  
établi sur la base des dernières revendications  
déposées avant le commencement de la recherche

N° d'enregistrement  
national

FA 667775  
FR 0506089

DOCUMENTS CONSIDÉRÉS COMME PERTINENTS		Revendication(s) concernée(s)	Classement attribué à l'invention par l'INPI
Catégorie	Citation du document avec indication, en cas de besoin, des parties pertinentes		
A	US 2005/043548 A1 (CATES JOSEPH) 24 février 2005 (2005-02-24) * abrégé *	1-18	
A	FR 2 863 080 A (ADVESTIGO) 3 juin 2005 (2005-06-03) * abrégé *	1-18	
			DOMAINES TECHNIQUES RECHERCHÉS (IPC)
		Date d'achèvement de la recherche	Examineur
		15 mars 2006	Bertolissi, E
CATÉGORIE DES DOCUMENTS CITÉS		T : théorie ou principe à la base de l'invention E : document de brevet bénéficiant d'une date antérieure à la date de dépôt et qui n'a été publié qu'à cette date de dépôt ou qu'à une date postérieure. D : cité dans la demande L : cité pour d'autres raisons ..... & : membre de la même famille, document correspondant	
X : particulièrement pertinent à lui seul Y : particulièrement pertinent en combinaison avec un autre document de la même catégorie A : arrière-plan technologique O : divulgation non-écrite P : document intercalaire			

3  
EPO FORM 1503 12.99 (P04C14)

**ANNEXE AU RAPPORT DE RECHERCHE PRÉLIMINAIRE  
RELATIF A LA DEMANDE DE BREVET FRANÇAIS NO. FR 0506089 FA 667775**

La présente annexe indique les membres de la famille de brevets relatifs aux documents brevets cités dans le rapport de recherche préliminaire visé ci-dessus.

Les dits membres sont contenus au fichier informatique de l'Office européen des brevets à la date du 15-03-2006

Les renseignements fournis sont donnés à titre indicatif et n'engagent pas la responsabilité de l'Office européen des brevets, ni de l'Administration française

Document brevet cité au rapport de recherche	Date de publication	Membre(s) de la famille de brevet(s)	Date de publication
WO 02082271 A	17-10-2002	AUCUN	
WO 03067459 A	14-08-2003	AU 2003209006 A1 EP 1485815 A1	02-09-2003 15-12-2004
US 2005043548 A1	24-02-2005	AUCUN	
FR 2863080 A	03-06-2005	WO 2005055086 A1	16-06-2005