(12) DEMANDE INTERNATIONALE PUBLIÉE EN VERTU DU TRAITÉ DE COOPÉRATION EN MATIÈRE DE BREVETS (PCT)

(19) Organisation Mondiale de la Propriété Intellectuelle
Bureau international

(43) Date de la publication internationale
17 novembre 2016 (17.11.2016)

WIPO | PCT

(10) Numéro de publication internationale
WO 2016/181050 A1

(51) Classification internationale des brevets :
H04L 12/707 (2013.01)

(21) Numéro de la demande internationale :
PCT/FR2016/051012

(22) Date de dépôt international :
29 avril 2016 (29.04.2016)

(25) Langue de dépôt : français

(26) Langue de publication : français

(30) Données relatives à la priorité :
15 54289 13 mai 2015 (13.05.2015) FR

(71) Déposant : **BULL SAS** [FR/FR]; rue Jean Jaurès, 78340 Les Clayes sous Bois (FR).

(72) Inventeurs : **VIGNERAS, Pierre**; 7 Grande Rue, 91470 Angervilliers (FR). **QUINTIN, Jean Noël**; 1 rue Plaisance, 92340 Bourg La Reine (FR).

(74) Mandataires : **CABINET PLASSERAUD** et al.; 66, rue de la Chaussée d'Antin, 75440 Paris Cedex 09 (FR).

(81) États désignés *(sauf indication contraire, pour tout titre de protection nationale disponible)* : AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JP, KE, KG, KN, KP, KR, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, ZA, ZM, ZW.

(84) États désignés *(sauf indication contraire, pour tout titre de protection régionale disponible)* : ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), eurasien (AM, AZ, BY, KG, KZ, RU, TJ, TM), européen (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

Publiée :

— *avec rapport de recherche internationale (Art. 21(3))*

(54) **Title** : NETWORK OF EQUIPMENT INTERCONNECTED BY SWITCHES INCORPORATING ROUTING TABLES

(54) **Titre** : RESEAU D'EQUIPEMENTS INTERCONNECTES PAR DES COMMUTATEURS INTEGRANT DES TABLES DE ROUTAGE

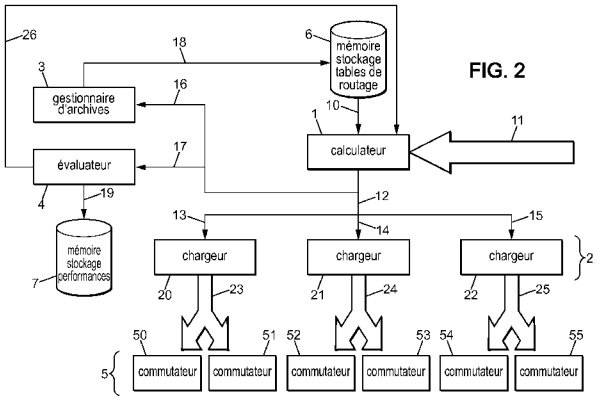

FIG. 2

3 Archive manager
4 Evaluator
7 Performance storage memory
6 Routing table storage memory
1 Computer
20 Loader
21 Loader
22 Loader
50 Switch
51 Switch
52 Switch
53 Switch
54 Switch
55 Switch

(57) Abstract : The invention relates to a network of equipment interconnected by switches (50 to 55) incorporating routing tables, comprising a routing table manager implementing two modes of operation, an off-line mode of operation in which all the routing tables are calculated initially, then loaded subsequently into the switches (50 to 55), at least when booting up the network, an on-line mode of operation in which, in case of an event rendering an element of the network unusable or operational, only the routing tables impacted by said event are recomputed and loaded into the switches (50 to 55), said routing tables being recomputed by a computer (1) of the routing table manager, said recomputed routing tables being loaded by several loaders (20 to 22) of routing tables of the routing table manager into their groups of respective switches (50 to 55).

(57) Abrégé : L'invention concerne un réseau d'équipements interconnectés par des commutateurs (50 à 55) intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de 5 fonctionnement, un mode de fonctionnement

[Suite sur la page suivante]

WO 2016/181050 A1

hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs (50 à 55), au moins lors du démarrage du réseau, un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, 10 seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs (50 à 55), lesdites tables de routage étant recalculées par un calculateur (1) du gestionnaire de tables de routage, lesdites tables de routage recalculées étant chargées par plusieurs chargeurs (20 à 22) de tables de routage du gestionnaire de tables de routage dans 15 leurs groupes de commutateurs (50 à 55) respectifs.

RESEAU D'EQUIPEMENTS INTERCONNECTES PAR DES COMMUTATEURS INTEGRANT DES TABLES DE ROUTAGE

DOMAINE DE L'INVENTION

L'invention concerne un réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage, ainsi qu'un procédé de mise à jour des tables de routage de ce réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage.

CONTEXTE DE L'INVENTION

Selon un art antérieur, il est connu un réseau dans lequel, lors de chaque panne d'équipement ou lors de chaque récupération d'équipement, l'ensemble des tables de routage est recalculé et directement chargé sur l'ensemble des commutateurs du réseau, sans pré-évaluation de l'efficacité de ces nouvelles tables de routage.

RESUME DE L'INVENTION

Le but de la présente invention est de fournir un réseau et un procédé de mise à jour des tables de routage de ce réseau palliant au moins partiellement les inconvénients précités.

Plus particulièrement, l'invention vise à fournir un réseau et un procédé de mise à jour des tables de routage de ce réseau pouvant rendre simultanément simple et efficace la mise à jour des tables de routage dans un réseau, lorsqu'un événement, par exemple panne d'équipement ou récupération d'équipement, rend nécessaire cette mise à jour.

Pour rendre simultanément aussi simple et efficace que possible la mise à jour des tables de routage dans le réseau, l'invention se propose de

résoudre une double problématique simultanée de la minimisation de la perturbation du réseau lors de la mise à jour des tables de routage et de la maximisation des performances du réseau pendant la mise à jour des tables de routage.

Pour cela, l'invention propose au niveau du réseau et du procédé de mise à jour des tables de routage, à la fois une amélioration au niveau architecture logicielle par un fonctionnement en bi-mode et au niveau architecture matérielle par la répartition des tables de routage sur plusieurs chargeurs distincts entre eux.

A cette fin, la présente invention propose un réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement : un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs, au moins lors du démarrage du réseau, un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs, lesdites tables de routage étant recalculées par un calculateur du gestionnaire de tables de routage, lesdites tables de routage recalculées étant chargées par plusieurs chargeurs de tables de routage du gestionnaire de tables de routage dans leurs groupes de commutateurs respectifs.

A cette fin, la présente invention propose aussi un procédé de mise à jour des tables de routage dans un réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement : un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs, au moins lors du démarrage du réseau, un mode de fonctionnement en ligne dans lequel, en

cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs, lesdites tables de routage étant recalculées par un calculateur du gestionnaire de tables de routage, lesdites tables de routage recalculées étant chargées par plusieurs chargeurs de tables de routage du gestionnaire de tables de routage dans leurs groupes de commutateurs respectifs.

Préférentiellement, dans le mode hors ligne, toutes les tables de routage sont calculées pour toute la topologie depuis le début et sont stockées, mais ne sont pas chargées dans un premier temps dans les commutateurs correspondants.

Préférentiellement, dans le mode en ligne, toutes les tables de routage ayant subi des modifications pour pouvoir contourner les pannes de liens ou d'équipements dans le réseau ou pour réintégrer les liens ou les équipements récupérés, sont calculées, sont stockées et sont chargées dans les commutateurs correspondants.

Dans une première forme dégradée de l'invention, où pour la double problématique simultanée de la minimisation de la perturbation du réseau lors de la mise à jour des tables de routage et de la maximisation des performances du réseau pendant la mise à jour des tables de routage, le premier aspect compte beaucoup plus que le second aspect, il est possible d'utiliser le fonctionnement en bi-mode sans la répartition des tables de routage sur plusieurs chargeurs.

Dans ce cas, il est alors proposé un réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement : un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs, au moins lors du démarrage du réseau, un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau,

seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs.

Dans ce cas, il est alors également proposé un procédé de mise à jour des tables de routage dans un réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement : un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs, au moins lors du démarrage du réseau, un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs.

Dans une deuxième forme dégradée de l'invention, où pour la double problématique simultanée de la minimisation de la perturbation du réseau lors de la mise à jour des tables de routage et de la maximisation des performances du réseau pendant la mise à jour des tables de routage, le premier aspect compte beaucoup moins que le second aspect, il est possible d'utiliser la répartition des tables de routage sur plusieurs chargeurs sans le fonctionnement en bi-mode.

Dans ce cas, il est alors proposé un réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage, comprenant un gestionnaire des tables de routage comprenant : un calculateur de tables de routage adapté pour recalculer, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seulement les tables de routage impactées par ledit événement, plusieurs chargeurs de tables de routage adaptés pour charger dans leurs groupes de commutateurs respectifs, seulement les tables de routage recalculées.

Dans ce cas, il est alors également proposé un procédé de mise à jour des tables de routage dans un réseau d'équipements interconnectés par des commutateurs intégrant des tables de routage, comprenant un gestionnaire

des tables de routage comprenant : un calculateur de tables de routage adapté pour recalculer, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seulement les tables de routage impactées par ledit événement, plusieurs chargeurs de tables de routage adaptés pour charger dans leurs groupes de commutateurs respectifs, seulement les tables de routage recalculées.

De cette manière, le calcul des tables de routage est découpé en deux parties. Dans une première partie, le gestionnaire de tables de routage fonctionne en mode hors ligne, mode dans lequel il peut calculer les tables de routage complètes sans réelle contrainte de temps. Dans une deuxième partie, le gestionnaire des tables de routage fonctionne en mode en ligne, mode dans lequel il ne va calculer que les modifications de tables de routage requises pour contourner la ou les pannes, le caractère limité de l'envergure de ces modifications permettant de mieux gérer la forte contrainte de temps existant dans ce mode en ligne.

Dans certains modes de réalisation, le mode hors ligne est utilisé au démarrage du réseau, pour initialiser l'ensemble des commutateurs du réseau. Les tables de routage ainsi calculées sont chargées dans un second temps, par exemple après leur validation par le gestionnaire de tables de routage. Une fois que les tables de routage sont chargées vers les commutateurs du réseau, le mode en ligne est lancé. Le gestionnaire des tables de routage charge les tables de routage précédentes dans sa mémoire, et s'abonne aux évènements provenant du réseau, comme par exemple la perte d'un lien entre équipements ou la récupération d'un lien entre équipements, ou comme par exemple la perte ou la récupération d'un équipement. Lorsqu'un évènement survient, par exemple de type panne ou récupération, le mode en ligne recalcule seulement les modifications nécessaires et suffisantes pour contourner cette panne, ou le cas échéant pour réutiliser un lien préalablement en panne à nouveau récupéré, c'est-à-dire devenu à nouveau disponible.

Ce mode en ligne confère ainsi deux avantages principaux. Un premier avantage est le temps de calcul réduit au strict nécessaire, ce qui a pour effet de permettre le masquage de la panne en réalisant l'opération en un temps inférieur au temps d'arrêt (« timeout » en langue anglaise) des applications MPI (pour « Message Passing Interface » en langue anglaise) qui est typiquement 10 secondes. Un deuxième avantage est l'impact qui est réduit au strict nécessaire ; en effet, seules quelques sous-parties du réseau sont impactées, réduisant alors d'autant le nombre global d'applications MPI qui sont impactées.

Dans certains modes de réalisation, le calcul des tables de routage sur un réseau comprenant N équipements terminaux, requiert le calcul de N^2 routes au minimum. Le support du routage adaptatif augmente encore significativement le nombre de ces routes à calculer. Lorsque N est grand, la panne d'un lien est une opération relativement courante qui devrait le moins possible impacter les applications. Recalculer l'ensemble des tables de routage permettant de contourner la ou les pannes requiert un temps de calcul qu'il est difficile de masquer aux applications. De plus, en recalculant ainsi l'ensemble des tables de routage, l'ensemble du réseau d'interconnexion va être impacté alors qu'une partie seulement du réseau était affectée par la panne.

Dans certains modes de réalisation, le temps de recalcul des tables de routage impactées par la panne ou la récupération d'un équipement ou d'un lien du réseau, est inférieure à 10 secondes, ce qui garantit une perturbation minimale des applications tournant sur le réseau.

Suivant des modes de réalisation préférés, l'invention comprend une ou plusieurs des caractéristiques suivantes qui peuvent être utilisées séparément ou en combinaison partielle entre elles ou en combinaison totale entre elles, avec l'un quelconque des objets précités de l'invention.

De préférence, le gestionnaire des tables de routage comprend un gestionnaire d'archives stockant au cours du temps d'une part les jeux de tables de routage ayant été utilisés dans le réseau et d'autre part les

topologies de réseau correspondantes. Ainsi, un historique des configurations successives des tables de routage du réseau est disponible et peut être utilisé pour plusieurs fonctions.

De préférence, le dernier jeu de tables de routage archivé va être chargé dans le calculateur lors du prochain redémarrage du réseau. Ainsi, lors du prochain redémarrage du réseau, le réseau va pouvoir fonctionner avec un jeu de tables de routage adapté et pratiquement optimisé car la topologie du réseau sera très proche de celle correspondant au jeu de tables de routage stocké.

De préférence, le gestionnaire des tables de routage comprend un évaluateur de tables de routage adapté pour évaluer les performances d'un jeu de tables de routage en fonction de la topologie correspondante de réseau, avant que ce jeu de tables de routage ne soit envoyé aux chargeurs. Une évaluation fine et réaliste peut notamment être faite grâce à l'historique stocké des jeux de tables de routage successifs dans le temps permettant alors de valider et d'affiner les simulations futures par les réalisations passées.

De préférence, l'évaluateur vérifie, pour chaque jeu de tables de routage avant son envoi aux chargeurs, l'absence d'impasse dans la topologie correspondante du réseau, l'absence de boucle vivante dans la topologie correspondante du réseau, l'absence d'interblocage dans la topologie correspondante du réseau. Une impasse est une adresse qui n'existe pas, l'envoi d'un paquet de données vers cette adresse étant alors forcément perdu. Une boucle vivante est un paquet qui tourne indéfiniment sur plusieurs commutateurs sans jamais aller vers un équipement terminal de réseau. Un interblocage comprend des paquets bloqués en boucle, chaque paquet étant bloqué par le précédent. L'absence d'impasse, de boucle vivante et d'interblocage, élimine les plus gros risques de dysfonctionnement du réseau après le chargement du nouveau jeu de tables de routage.

Le gestionnaire de tables de routage a la capacité de stocker sur disque les tables de routage ainsi calculées sans les charger tout de suite vers les commutateurs, ce qui permet d'abord de les analyser, notamment au niveau de la qualité du routage. Les trois principales propriétés d'une bonne qualité de routage sont : l'absence d'interblocage (« deadlock » en langue anglaise), l'absence de boucle ouverte (« livelock » en langue anglaise), et l'absence d'impasse (« deadend » en langue anglaise). A ces trois principales propriétés peuvent se rajouter l'équilibrage des routes, c'est-à-dire pas de sur utilisation ni ne de sous-utilisation des liens existant entre équipements.

De préférence, le gestionnaire des tables de routage comprend une boucle de rétroaction de l'évaluateur vers le calculateur pour que le calculateur réalise un calcul itératif ou un recalcul itératif des tables de routage. Ainsi, les tables de routage vont être parfaitement optimisées dans la mesure où elles vont être recalculées tant qu'elles ne sont pas optimales.

De préférence, le calculateur implémente un algorithme de sélection des tables de routage à recalculer qui, en cas de panne d'un commutateur, d'une part sélectionne en priorité les commutateurs situés dans la couche amont et dans la couche aval par rapport au sens de transmission des données dans le réseau, et d'autre part ne sélectionne pas les commutateurs situés dans la même couche, par rapport au sens de transmission des données, que le commutateur tombé en panne. Il s'agit d'une part de stopper au plus près, en amont et en aval, les flots de paquets de données se dirigeant vers le commutateur tombé en panne, afin de les obliger à contourner le commutateur tombé en panne, et d'autre part de ne pas perturber ou de perturber le moins possible les flots de paquets de données qui contournent déjà le commutateur tombé en panne, car la circulation de ces flots est déjà adaptée à la panne du commutateur défectueux.

De préférence, les différents composants du gestionnaire de tables de routage tournent en tâches de fond, de préférence sous UNIX. Ainsi, d'une part les tables de routage sont recalculées de manière permanente et immédiate dès qu'un événement de type panne ou récupération

d'équipement est détecté, et d'autre part, ces tables de routage sont recalculées sans gêner directement le déroulement du traitement de données ou du calcul de données effectué par l'ensemble des équipements du réseau à un moment donné.

De préférence, le calculateur implémente un algorithme de routage qui est adapté pour recalculer les tables de routage et qui est sans connaissance préalable de la topologie du réseau. Ainsi, cet algorithme de routage reste efficace quelle que soit l'endroit où la panne ou la récupération d'équipement survient, et quelle que soit l'évolution des pannes ou des récupérations au sein du réseau.

De préférence, le gestionnaire des tables de routage implémente une commande de charge des tables de routage dans les commutateurs. Cette commande supplémentaire permet au gestionnaire des tables de routage de lui-même charger les tables de routage dans les commutateurs, et ceci, de manière circonscrite à la stricte nécessité entraînée par la panne ou la récupération.

De préférence, le gestionnaire des tables de routage utilise un identifiant de connexion vers les mises à jour de statut des équipements du réseau. Cet identifiant de connexion permet au gestionnaire des tables de routage d'obtenir directement et par lui-même le statut des équipements du réseau dont l'évolution reflète l'évolution de la topologie du réseau.

De préférence, les équipements de réseau comprennent une majorité de nœuds de calcul. Le réseau comprend une minorité d'équipements intermédiaires, par exemple des commutateurs, et une majorité d'équipements terminaux, par exemple des nœuds de calcul. Tous les équipements sont reliés entre eux par des liens dans le réseau.

Le réseau comprend un grand nombre de nœuds de calcul, de préférence plus de 5000 nœuds de calcul, plus de préférence plus de 20000 nœuds de calcul, encore plus de préférence plus de 50000 de nœuds de calcul. Ce réseau est alors considéré comme un réseau d'interconnexion rapide à grande échelle.

D'autres caractéristiques et avantages de l'invention apparaîtront à la lecture de la description qui suit d'un mode de réalisation préféré de l'invention, donnée à titre d'exemple et en référence aux dessins annexés.

BREVE DESCRIPTION DES DESSINS

La figure 1 représente schématiquement un exemple de déroulement du mode hors ligne dans le gestionnaire de tables de routage selon un mode de réalisation de l'invention.

La figure 2 représente schématiquement un exemple de déroulement du mode en ligne dans le gestionnaire de tables de routage selon un mode de réalisation de l'invention.

DESCRIPTION DETAILLEE DE L'INVENTION

La figure 1 représente schématiquement un exemple de déroulement du mode hors ligne dans le gestionnaire de tables de routage selon un mode de réalisation de l'invention. En mode hors ligne, le gestionnaire de tables de routage comprend une mémoire A de topologie, un diviseur B de réseau en sous-parties, des calculateurs C, D et E, de sous-parties, un connecteur F de sous-parties en routes, une mémoire G de stockage de tables de routage. Seuls trois calculateurs C à E de sous-parties sont représentés pour la clarté de la figure 1, mais il en existe en général nettement plus.

La topologie du réseau est stockée dans la mémoire A. La topologie du réseau est transmise de la mémoire A vers le diviseur B. Le diviseur B sépare le réseau en sous-parties qui vont pouvoir être calculées séparément, respectivement par les trois calculateurs C à E. Une fois chaque sous-partie calculée séparément, les routes sont reconstituées à partir de ces sous-parties reliées entre elles par le connecteur F. Ces routes sont ensuite stockés dans la mémoire G, pour pouvoir être chargées dans les commutateurs le moment venu.

Le mode hors-ligne peut-être un matériel ou un logiciel prenant en entrée un nom d'algorithme et une topologie, par exemple sous la forme d'un fichier. Les tables de routage sont écrites en sortie en mémoire, laquelle mémoire peut être une mémoire flash, un mémoire ram, ou un disque mémoire. Le mode hors ligne utilise une commande annexe permettant de charger les tables de routage stockées dans la mémoire G, sur chaque commutateur du réseau d'interconnexion.

La figure 2 représente schématiquement un exemple de déroulement du mode en ligne dans le gestionnaire de tables de routage selon un mode de réalisation de l'invention. Le gestionnaire de tables de routage comprend un calculateur 1 des tables de routage, un ensemble 2 de chargeurs 20 à 22 des tables de routage dans les commutateurs, un gestionnaire d'archives 3 des jeux de tables de routage, un évaluateur 4 des jeux de tables de routage, un ensemble 5 de commutateurs 50 à 55, une mémoire 6 de stockage des jeux de tables de routage et des topologies associées de réseau, une mémoire 7 de stockage des performances des jeux de tables de routage. Seuls trois chargeurs 20 à 22 sont représentés pour la clarté de la figure 2, mais il en existe en général nettement plus. Seuls six commutateurs 50 à 55 sont représentés pour la clarté de la figure 2, mais il en existe en général nettement plus.

Un lien 10 permet la charge d'un jeu de tables de routage dans le calculateur 1. Un lien 11 permet au calculateur 1 de recevoir les mises à jour concernant les statuts des équipements du réseau. Un lien 12 permet la publication des modifications de tables de routage, préalablement calculées par le calculateur 1. Des liens 13 à 15 permettent l'envoi à chaque chargeur 20 à 22 des sous-ensembles de tables de routage qui lui sont associées. Des liens 23 à 25 permettent la distribution à chaque commutateur 50 à 55 des tables de routage qui lui sont associées, par exemple par l'intermédiaire du protocole SNMP (pour « Single Network Management Protocol » en langue anglaise). Le lien 16 permet l'envoi, au gestionnaire d'archives 3, de l'ensemble des tables de routage d'un jeu de tables de routage. Le lien 17

permet l'envoi, à l'évaluateur 4, de l'ensemble des tables de routage d'un jeu de tables de routage. Le lien 18 permet au gestionnaire d'archives 3 de stocker, dans la mémoire 6, le jeu de tables de routage en l'associant à la topologie correspondante de réseau. Le lien 19 permet à l'évaluateur 4 de stocker, dans la mémoire 7, les performances du jeu de tables de routage, préalablement évaluées par l'évaluateur 4. Un lien 26 permet une boucle de rétroaction de l'évaluateur 4 vers le calculateur 1, de manière à ce que, par itérations successives, l'évaluation des performances du jeu de tables de routage dans le réseau permette de recalculer ce jeu de tables de routage jusqu'à convergence.

Le mode en ligne est implémenté au travers de tâches de fond (« daemons » en langue anglaise) distribuées sous UNIX.

Le calculateur 1 reçoit les mises à jour des statuts des équipements du réseau en provenance du cœur de réseau, calcule les modifications des tables de routage et les publie. Le calculateur 1 n'a qu'un droit de lecture seule de la mémoire 6.

Les chargeurs 20 à 22 reçoivent certaines modifications des tables de routage, celles qui leur sont associées, et les charge dans les commutateurs 50 à 55 qui leur sont associés par l'intermédiaire du protocole SNMP.

Le gestionnaire d'archives 3 reçoit toutes les modifications des tables de routage et les stocke dans la mémoire 6. Le gestionnaire d'archives 3 a un droit de lecture de la mémoire 6 et un droit d'écriture de la mémoire 6.

L'évaluateur 4 reçoit toutes les modifications des tables de routage, réalise les évaluations des performances liées à ces modifications des tables de routage, et stocke ces performances évaluées dans la mémoire 7. L'évaluateur 4 a un droit de lecture de la mémoire 7 et un droit d'écriture de la mémoire 7.

Le mode en ligne peut être un matériel ou un logiciel prenant en entrée un nom d'algorithme, une topologie, et un identifiant de connexion vers les mises à jour des statuts des équipements du réseau, ledit statut pouvant être par exemple « équipement en panne » ou au contraire

« équipement récupéré ». En sortie, le mode en ligne charge les modifications des tables de routage sur les commutateurs 50 à 55 et stocke aussi sur la mémoire 6, qui est par exemple une mémoire disque, le nouveau jeu de tables de routage.

Pour recalculer un jeu de tables de routage, un algorithme est utilisé, il peut par exemple être un algorithme en ligne pour PGFT (pour « Parallel Ports Generalized Fat-Tree » en langue anglaise) ou bien un algorithme en ligne sans connaissance de la topologie du réseau (« topology agnostic algorithm » en langue anglaise).

L'algorithme de recalcul en ligne des tables de routage va contourner les équipements ou les liens tombés en panne, réutiliser les liens ou les équipements réparés et à nouveau opérationnels, effectuer le recalcul dans une durée inférieure à la durée de temps mort des applications, généralement environ 10 secondes, qui tournent sur le réseau, détecter l'impossibilité de recalculer les tables de routage parce-que la topologie du réseau n'est plus routable et dans ce cas, en informer l'administrateur du système.

L'algorithme en ligne pour PGFT permet de calculer seulement des modifications de table de routage adaptées au contournement des pannes qui peuvent subvenir dans une topologie de type PGFT (« fat-tree » en langue anglaise). L'architecture en ligne permet d'utiliser cet algorithme afin de minimiser l'impact des pannes sur l'ensemble du réseau constituant un supercalculateur lorsqu'il est connecté comme un PGFT.

L'algorithme en ligne sans connaissance de la topologie du réseau permet de calculer seulement des modifications des tables de routage adaptées au contournement des pannes qui peuvent survenir dans n'importe quelle topologie. L'architecture en ligne permet d'utiliser cet algorithme afin de minimiser l'impact des pannes sur l'ensemble du réseau constituant un supercalculateur.

Une table de routage comprend généralement au moins les informations suivantes. D'abord, un identifiant de réseau. Ensuite, la

prochaine étape (« next hop » ou « next gateway » en langue anglaise) qui est l'adresse du prochain élément de réseau auquel le paquet de données va être envoyé sur son chemin pour arriver à sa destination finale. Une table de routage peut également contenir un ou plusieurs des éléments suivants, afin de raffiner le routage des paquets de données. Par exemple, la qualité de service associée à la route. Par exemple, les listes d'accès associées à la route.

Bien entendu, la présente invention n'est pas limitée aux exemples et au mode de réalisation décrits et représentés, mais elle est susceptible de nombreuses variantes accessibles à l'homme de l'art.

REVENDICATIONS

1. Réseau d'équipements interconnectés par des commutateurs (50 à 55) intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement :
   - un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs (50 à 55), au moins lors du démarrage du réseau,
   - un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs (50 à 55),
     - lesdites tables de routage étant recalculées par un calculateur (1) du gestionnaire de tables de routage,
     - lesdites tables de routage recalculées étant chargées par plusieurs chargeurs (20 à 22) de tables de routage du gestionnaire de tables de routage dans leurs groupes de commutateurs (50 à 55) respectifs.

2. Réseau d'équipements interconnectés par des commutateurs (50 à 55) intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement :
   - un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs (50 à 55), au moins lors du démarrage du réseau,
   - un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du

réseau, seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs (50 à 55).

3. Réseau d'équipements interconnectés par des commutateurs (50 à 55) intégrant des tables de routage, comprenant un gestionnaire des tables de routage comprenant :
   - un calculateur (1) de tables de routage adapté pour recalculer, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seulement les tables de routage impactées par ledit événement,
   - plusieurs chargeurs (20 à 22) de tables de routage adaptés pour charger dans leurs groupes de commutateurs (50 à 55) respectifs, seulement les tables de routage recalculées.

4. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que le gestionnaire des tables de routage comprend un gestionnaire d'archives (3) stockant au cours du temps d'une part les jeux de tables de routage ayant été utilisés dans le réseau et d'autre part les topologies de réseau correspondantes.

5. Réseau selon la revendication 4, caractérisé en ce que le dernier jeu de tables de routage archivé va être chargé dans le calculateur (1) lors du prochain redémarrage du réseau.

6. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que le gestionnaire des tables de routage comprend un évaluateur (4) de tables de routage adapté pour évaluer les performances d'un jeu de tables de routage en fonction de la topologie correspondante de réseau, avant que ce jeu de tables de routage ne soit envoyé aux chargeurs (20 à 22).

7. Réseau selon la revendication 6, caractérisé en ce que l'évaluateur (4) vérifie, pour chaque jeu de tables de routage avant son envoi aux chargeurs (20 à 22), l'absence :
   - d'impasse dans la topologie correspondante du réseau,
   - de boucle vivante dans la topologie correspondante du réseau,
   - d'interblocage dans la topologie correspondante du réseau.

8. Réseau selon l'une quelconque des revendications 6 à 7, caractérisé en ce que le gestionnaire des tables de routage comprend une boucle de rétroaction (26) de l'évaluateur (4) vers le calculateur (1) pour que le calculateur (1) réalise un calcul itératif ou un recalcul itératif des tables de routage.

9. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que le calculateur (1) implémente un algorithme de sélection des tables de routage à recalculer qui, en cas de panne d'un commutateur (50 à 55), d'une part sélectionne en priorité les commutateurs (50 à 55) situés dans la couche amont et dans la couche aval par rapport au sens de transmission des données dans le réseau, et d'autre part ne sélectionne pas les commutateurs (50 à 55) situés dans la même couche, par rapport au sens de transmission des données, que le commutateur (50 à 55) tombé en panne.

10. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que les différents composants du gestionnaire de tables de routage tournent en tâches de fond, de préférence sous UNIX.

11. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que le calculateur implémente un algorithme de routage qui est adapté pour recalculer les tables de routage et qui est sans connaissance préalable de la topologie du réseau.

12. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que le gestionnaire des tables de routage implémente une commande de charge des tables de routage dans les commutateurs (50 à 55).

13. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que le gestionnaire des tables de routage utilise un identifiant de connexion vers les mises à jour de statut des équipements du réseau.

14. Réseau selon l'une quelconque des revendications précédentes, caractérisé en ce que les équipements de réseau comprennent une majorité de nœuds de calcul.

15. Réseau selon la revendication 14, caractérisé en ce que le réseau comprend plus de 5000 nœuds de calcul, de préférence plus de 20000 de nœuds de calcul.

16. Procédé de mise à jour des tables de routage dans un réseau d'équipements interconnectés par des commutateurs (50 à 55) intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement :

- un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs (50 à 55), au moins lors du démarrage du réseau,
- un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs (50 à 55),

- lesdites tables de routage étant recalculées par un calculateur (1) du gestionnaire de tables de routage,
- lesdites tables de routage recalculées étant chargées par plusieurs chargeurs (20 à 22) de tables de routage du gestionnaire de tables de routage dans leurs groupes de commutateurs (50 à 55) respectifs.

17. Procédé de mise à jour des tables de routage dans un réseau d'équipements interconnectés par des commutateurs (50 à 55) intégrant des tables de routage, comprenant un gestionnaire des tables de routage implémentant deux modes de fonctionnement :
    - un mode de fonctionnement hors ligne dans lequel, toutes les tables de routage sont calculées dans un premier temps, puis chargées dans un deuxième temps dans les commutateurs (50 à 55), au moins lors du démarrage du réseau,
    - un mode de fonctionnement en ligne dans lequel, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seules les tables de routage impactées par ledit événement sont recalculées et chargées dans les commutateurs (50 à 55).

18. Procédé de mise à jour des tables de routage dans un réseau d'équipements interconnectés par des commutateurs (50 à 55) intégrant des tables de routage, comprenant un gestionnaire des tables de routage comprenant :
    - un calculateur (1) de tables de routage adapté pour recalculer, en cas d'événement rendant inutilisable ou opérationnel un élément du réseau, seulement les tables de routage impactées par ledit événement,
    - plusieurs chargeurs (20 à 22) de tables de routage adaptés pour charger dans leurs groupes de commutateurs (50 à 55) respectifs, seulement les tables de routage recalculées.

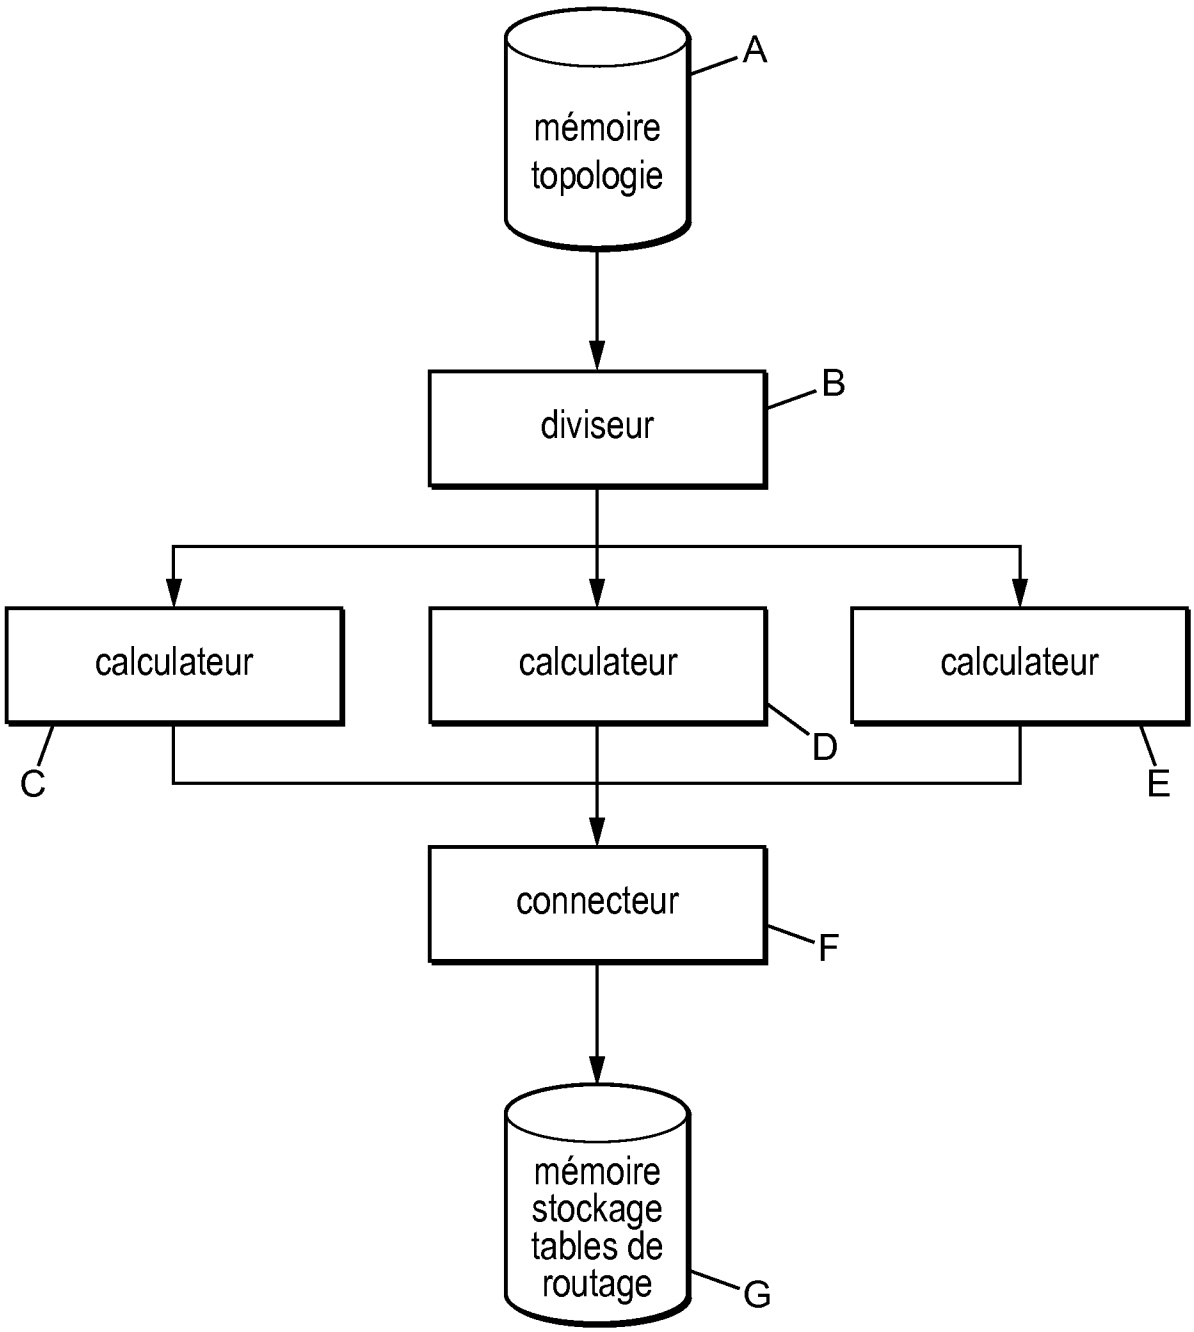
mémoire topologie
A
diviseur
B
calculateur
calculateur
calculateur
C
D
E
connecteur
F
mémoire stockage tables de routage
G

FIG. 1

FIG. 2

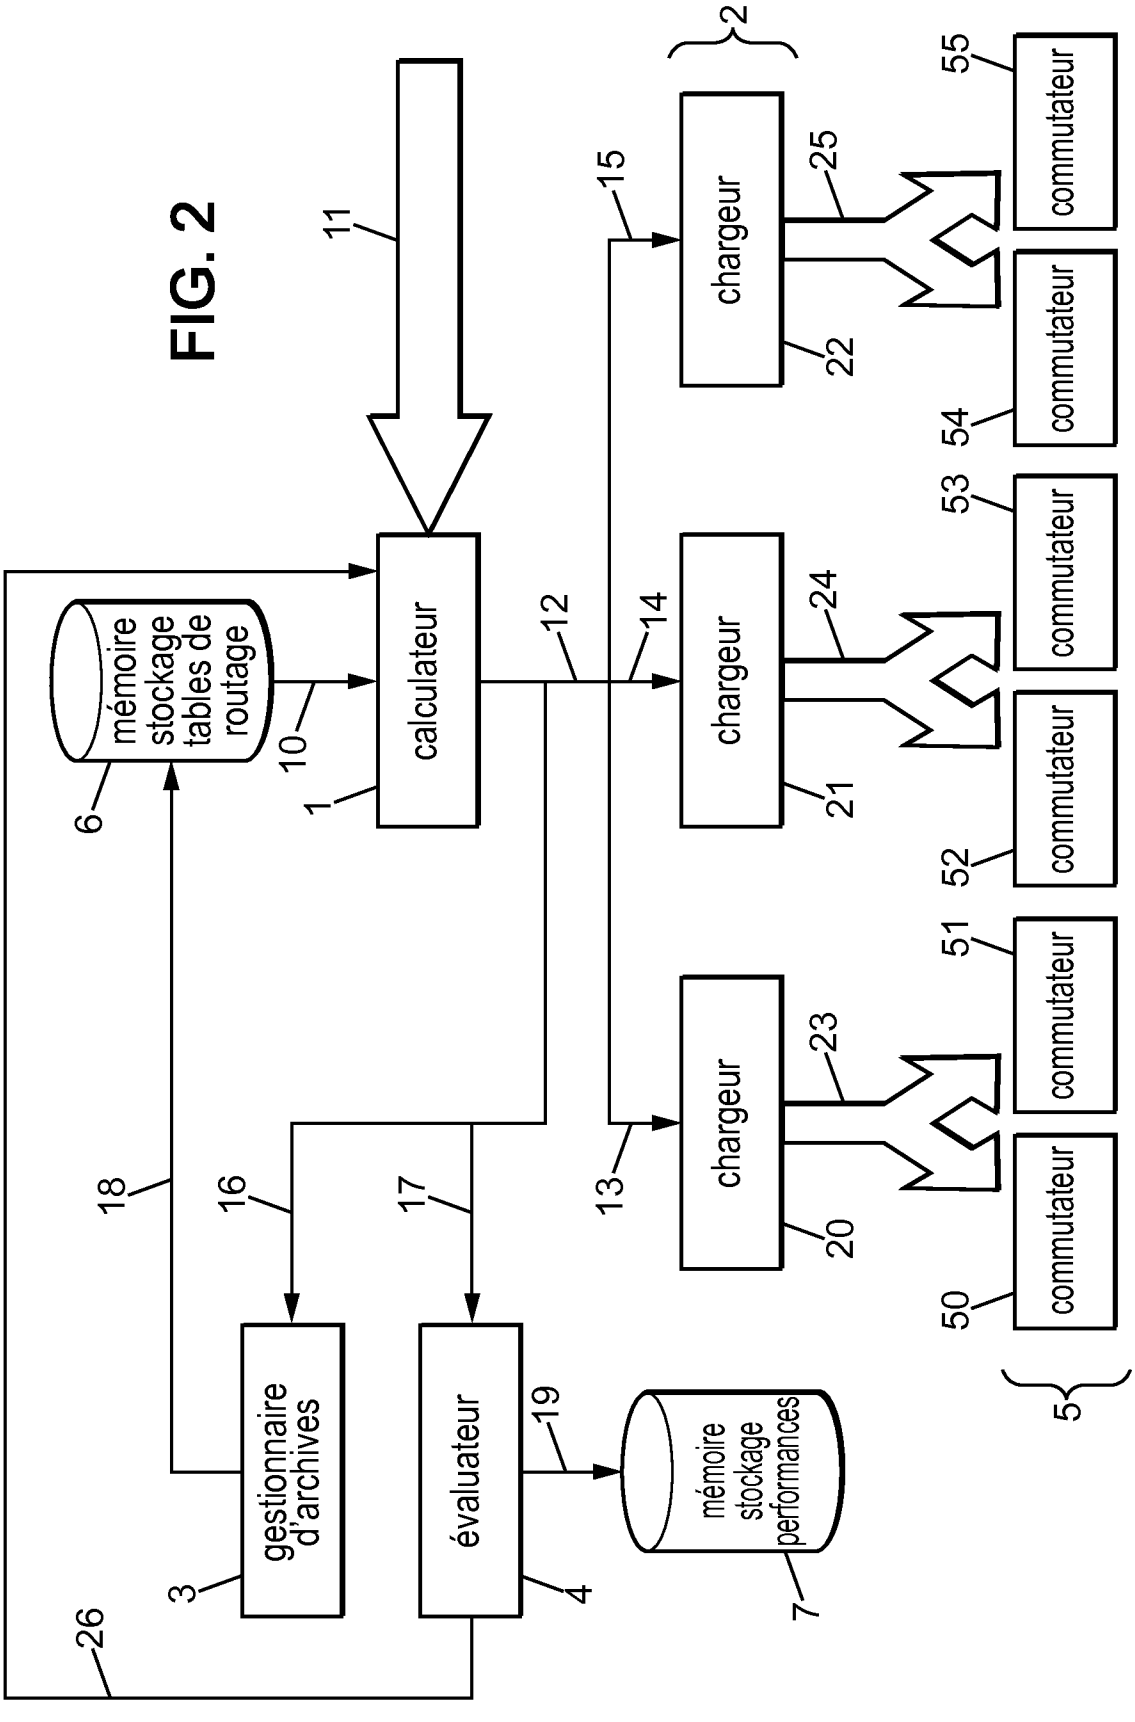
mémoire stockage tables de routage
calculateur
chargeur
chargeur
chargeur
commutateur
commutateur
commutateur
commutateur
commutateur
commutateur
commutateur
commutateur
gestionnaire d'archives
évaluateur
mémoire stockage performances
1
2
3
4
5
6
7
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
50
51
52
53
54
55

INTERNATIONAL SEARCH REPORT

International application No
PCT/FR2016/051012

A. CLASSIFICATION OF SUBJECT MATTER
INV. H04L12/707
ADD.

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)
H04L

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)
EPO-Internal

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
X	EP 2 437 446 A1 (ERICSSON TELEFON AB L M [SE]) 4 April 2012 (2012-04-04)	3,18
A	abstract paragraphs [0005] - [0008], [0030] - [0033]	1,2,4-17

A	WO 01/76269 A1 (BRITISH TELECOMM [GB]; SHIPMAN ROBERT ANDREW [GB]) 11 October 2001 (2001-10-11) abstract page 6, line 1 - page 7, line 16; claim 1	1-18

A	EP 2 498 456 A1 (BROADCOM CORP [US]) 12 September 2012 (2012-09-12) abstract paragraphs [0150] - [0175]	1-18

	-/--	

[X] Further documents are listed in the continuation of Box C.

[X] See patent family annex.

* Special categories of cited documents :

"A" document defining the general state of the art which is not considered to be of particular relevance

"E" earlier application or patent but published on or after the international filing date

"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

"O" document referring to an oral disclosure, use, exhibition or other means

"P" document published prior to the international filing date but later than the priority date claimed

"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

"&" document member of the same patent family

Date of the actual completion of the international search	Date of mailing of the international search report
30 June 2016	08/07/2016

Name and mailing address of the ISA/	Authorized officer
European Patent Office, P.B. 5818 Patentlaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Fax: (+31-70) 340-3016	Le Bras, Patrick

1

Form PCT/ISA/210 (second sheet) (April 2005)

INTERNATIONAL SEARCH REPORT

International application No
PCT/FR2016/051012

C(Continuation). DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	US 6 097 718 A (BION JOEL P [US]) 1 August 2000 (2000-08-01) abstract column 2, line 5 - column 3, line 2 -----	1-18

1

INTERNATIONAL SEARCH REPORT

Information on patent family members

International application No
PCT/FR2016/051012

Patent document cited in search report	Publication date	Patent family member(s)	Publication date
EP 2437446 A1	04-04-2012	EP 2437446 A1	04-04-2012
		US 2012075986 A1	29-03-2012
WO 0176269 A1	11-10-2001	AU 4262401 A	15-10-2001
		CA 2403772 A1	11-10-2001
		EP 1269770 A1	02-01-2003
		US 2003048771 A1	13-03-2003
		WO 0176269 A1	11-10-2001
EP 2498456 A1	12-09-2012	CN 102684990 A	19-09-2012
		EP 2498456 A1	12-09-2012
		KR 20120102026 A	17-09-2012
		TW 201246845 A	16-11-2012
		US 2012230342 A1	13-09-2012
		US 2014140214 A1	22-05-2014
US 6097718 A	01-08-2000	US 6097718 A	01-08-2000
		US 6327251 B1	04-12-2001

RAPPORT DE RECHERCHE INTERNATIONALE

Demande internationale n°
PCT/FR2016/051012

A. CLASSEMENT DE L'OBJET DE LA DEMANDE
INV. H04L12/707
ADD.

Selon la classification internationale des brevets (CIB) ou à la fois selon la classification nationale et la CIB

B. DOMAINES SUR LESQUELS LA RECHERCHE A PORTE

Documentation minimale consultée (système de classification suivi des symboles de classement)
H04L

Documentation consultée autre que la documentation minimale dans la mesure où ces documents relèvent des domaines sur lesquels a porté la recherche

Base de données électronique consultée au cours de la recherche internationale (nom de la base de données, et si cela est réalisable, termes de recherche utilisés)
EPO-Internal

C. DOCUMENTS CONSIDERES COMME PERTINENTS

Catégorie*	Identification des documents cités, avec, le cas échéant, l'indication des passages pertinents	no. des revendications visées
X	EP 2 437 446 A1 (ERICSSON TELEFON AB L M [SE]) 4 avril 2012 (2012-04-04)	3,18
A	abrégé alinéas [0005] - [0008], [0030] - [0033]	1,2,4-17
A	WO 01/76269 A1 (BRITISH TELECOMM [GB]; SHIPMAN ROBERT ANDREW [GB]) 11 octobre 2001 (2001-10-11) abrégé page 6, ligne 1 - page 7, ligne 16; revendication 1	1-18
A	EP 2 498 456 A1 (BROADCOM CORP [US]) 12 septembre 2012 (2012-09-12) abrégé alinéas [0150] - [0175]	1-18

-/--

[X] Voir la suite du cadre C pour la fin de la liste des documents

[X] Les documents de familles de brevets sont indiqués en annexe

* Catégories spéciales de documents cités:

"A" document définissant l'état général de la technique, non considéré comme particulièrement pertinent

"E" document antérieur, mais publié à la date de dépôt international ou après cette date

"L" document pouvant jeter un doute sur une revendication de priorité ou cité pour déterminer la date de publication d'une autre citation ou pour une raison spéciale (telle qu'indiquée)

"O" document se référant à une divulgation orale, à un usage, à une exposition ou tous autres moyens

"P" document publié avant la date de dépôt international, mais postérieurement à la date de priorité revendiquée

"T" document ultérieur publié après la date de dépôt international ou la date de priorité et n'appartenant pas à l'état de la technique pertinent, mais cité pour comprendre le principe ou la théorie constituant la base de l'invention

"X" document particulièrement pertinent; l'invention revendiquée ne peut être considérée comme nouvelle ou comme impliquant une activité inventive par rapport au document considéré isolément

"Y" document particulièrement pertinent; l'invention revendiquée ne peut être considérée comme impliquant une activité inventive lorsque le document est associé à un ou plusieurs autres documents de même nature, cette combinaison étant évidente pour une personne du métier

"&" document qui fait partie de la même famille de brevets

Date à laquelle la recherche internationale a été effectivement achevée	Date d'expédition du présent rapport de recherche internationale
30 juin 2016	08/07/2016

Nom et adresse postale de l'administration chargée de la recherche internationale	Fonctionnaire autorisé
Office Européen des Brevets, P.B. 5818 Patentlaan 2 NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Fax: (+31-70) 340-3016	Le Bras, Patrick

1

RAPPORT DE RECHERCHE INTERNATIONALE

Demande internationale n°
PCT/FR2016/051012

C(suite). DOCUMENTS CONSIDERES COMME PERTINENTS

Catégorie*	Identification des documents cités, avec, le cas échéant, l'indication des passages pertinents	no. des revendications visées
A	US 6 097 718 A (BION JOEL P [US]) 1 août 2000 (2000-08-01) abrégé colonne 2, ligne 5 - colonne 3, ligne 2 -----	1-18

1

RAPPORT DE RECHERCHE INTERNATIONALE

Renseignements relatifs aux membres de familles de brevets

Demande internationale n°
PCT/FR2016/051012

Document brevet cité au rapport de recherche	Date de publication	Membre(s) de la famille de brevet(s)	Date de publication
EP 2437446 A1	04-04-2012	EP 2437446 A1	04-04-2012
		US 2012075986 A1	29-03-2012
WO 0176269 A1	11-10-2001	AU 4262401 A	15-10-2001
		CA 2403772 A1	11-10-2001
		EP 1269770 A1	02-01-2003
		US 2003048771 A1	13-03-2003
		WO 0176269 A1	11-10-2001
EP 2498456 A1	12-09-2012	CN 102684990 A	19-09-2012
		EP 2498456 A1	12-09-2012
		KR 20120102026 A	17-09-2012
		TW 201246845 A	16-11-2012
		US 2012230342 A1	13-09-2012
		US 2014140214 A1	22-05-2014
US 6097718 A	01-08-2000	US 6097718 A	01-08-2000
		US 6327251 B1	04-12-2001