

RECOMMANDATION UIT-R BS.1387

MÉTHODE DE MESURE OBJECTIVE DE LA QUALITÉ DU SON PERÇU

(Question UIT-R 210/10)

(1998)

L'Assemblée des radiocommunications de l'UIT,

considérant

- a) que les méthodes objectives traditionnelles (par exemple de mesure du rapport signal/bruit et de la distorsion) ne sont plus adaptées à la mesure de la qualité du son perçu de systèmes qui utilisent des schémas de codage à faible débit binaire ou un traitement des signaux analogiques ou numériques;
- b) que les schémas de codage à faible débit binaire sont rapidement mis en service;
- c) que les réalisations conformes à une spécification ou une norme ne garantissent pas toutes la meilleure qualité possible avec cette spécification ou cette norme;
- d) que les méthodes formelles d'évaluation subjective ne sont pas adaptées au contrôle continu de la qualité du son, par exemple en conditions d'exploitation;
- e) que la mesure objective de la qualité du son perçu peuvent éventuellement compléter ou remplacer les méthodes d'essai objectives traditionnelles dans tous les domaines de mesure;
- f) que la mesure objective de la qualité du son perçu peuvent utilement compléter les méthodes d'évaluation subjective;
- g) que, pour certaines applications, une méthode qui puisse être appliquée en temps réel est nécessaire,

recommande

- 1 que pour les applications dont on trouvera la liste en Annexe 1, la méthode expliquée dans l'Annexe 2 soit utilisée pour la mesure objective de la qualité du son perçu.

AVANT-PROPOS

Cette Recommandation définit une méthode de mesure objective de la qualité du son perçu d'un système testé, par exemple un codec à faible débit binaire. Elle est composée de deux Annexes. L'Annexe 1 offre à l'utilisateur un aperçu général de la méthode et comporte quatre Appendices. L'Appendice 1 décrit les applications et les signaux de test. L'Appendice 2 est une liste des variables de sortie de modèle; on y trouvera également les limites d'utilisation et de précision. L'Appendice 3 est une description rapide du modèle et l'Appendice 4 décrit les principes et les caractéristiques générales des méthodes de mesure objective de la qualité du son perçu.

L'Annexe 2 offre au réalisateur une description détaillée de la méthode avec les deux versions du modèle psychoacoustique développées pendant la phase d'intégration lors de laquelle six modèles ont été associés. On trouvera dans l'Appendice 1 de l'Annexe 2 la description du processus de validation de la méthode de mesure objective. L'Appendice 2 de l'Annexe 2 survole toutes les bases de données utilisées pour le développement et la validation de la méthode.

TABLE DES MATIÈRES

	Page
AVANT-PROPOS	1
TABLE DES MATIÈRES	2
Annexe 1 – Aperçu général	6
1 Introduction	6
2 Applications.....	6
3 Versions.....	7
4 Le domaine subjectif	7
5 Résolution et précision	8
6 Exigences et limitations.....	9
Appendice 1 de l'Annexe 1 – Applications.....	9
1 Généralités.....	9
2 Applications principales	9
2.1 Evaluation des réalisations.....	9
2.2 Alignement qualité perceptuelle.....	10
2.3 Contrôle en ligne.....	10
2.4 Etat des équipements ou des connexions	10
2.5 Identification des codecs	10
2.6 Développement des codecs	10
2.7 Planification des réseaux.....	11
2.8 Aides à l'évaluation subjective.....	11
2.9 Résumé des applications	11
3 Les signaux d'essais.....	11
3.1 Sélection de signaux d'essais naturels.....	12
3.2 Durée.....	12
4 Synchronisation	13
5 Droits de reproduction	13
Appendice 2 de l'Annexe 1 – Variables de sortie	13
1 Introduction	13
2 Les variables de sortie de modèle.....	13
3 Qualité audio de base.....	13
4 Marge de codage.....	14
5 Exigences des utilisateurs.....	15
Appendice 3 de l'Annexe 1 – Présentation du modèle.....	15
1 Traitement du son	16
1.1 Paramètres définis par l'utilisateur	16
1.2 Modèle psychoacoustique	16
1.3 Modèle cognitif.....	16
Appendice 4 de l'Annexe 1 – Principes et caractéristiques des méthodes de mesure objective de la qualité perceptuelle du son	17
1 Introduction et historique.....	17
2 Structure générale des méthodes de mesure objective de mesure de la qualité perceptuelle du son.....	17

3	Considérations psychoacoustiques et cognitives	18
3.1	Caractéristique de transfert par l'oreille externe et par l'oreille moyenne	18
3.2	Echelles perceptuelles des fréquences.....	18
3.3	Excitation	19
3.4	Détection	20
3.5	Masquage	20
3.6	Intensité acoustique et masquage partiel.....	21
3.7	Acuité.....	21
3.8	Traitement cognitif.....	21
4	Les modèles intégrés	22
4.1	DIX	22
4.2	NMR	23
4.3	OASE	23
4.4	PAQM (Perceptual Audio Quality Measure).....	23
4.5	PERCEVAL.....	24
4.6	POM.....	24
4.7	L'Approche Toolbox	25
	Annexe 2 – Description du modèle.....	26
1	Généralités	26
1.1	Version de base	27
1.2	Version avancée	27
2	Modèle auditif périphérique	28
2.1	Modèle auditif FFT	28
2.1.1	Aperçu général	28
2.1.2	Traitement temporel	29
2.1.3	FFT	29
2.1.4	Oreille externe et oreille moyenne	30
2.1.5	Regroupement en bandes critiques.....	30
2.1.6	Ajout de bruit interne	36
2.1.7	Etalement.....	36
2.1.8	Etalement dans le domaine temporel.....	38
2.1.9	Seuil de masquage.....	38
2.2	Modèle auditif fondé sur un banc de filtres	39
2.2.1	Aperçu général	39
2.2.2	Sous-échantillonnage	40
2.2.3	Réglage niveau de reproduction	41
2.2.4	Filtre de réjection DC	41
2.2.5	Banc de filtres.....	41
2.2.6	Filtrage par l'oreille externe et par l'oreille moyenne	43
2.2.7	Etalement dans le domaine fréquentiel.....	44
2.2.8	Rectification	46
2.2.9	Dégradation dans le domaine temporel (1) – Prémassage	46
2.2.10	Ajout de bruit interne	46
2.2.11	Dégradation dans le domaine temporel (2) – Postmasquage.....	46
3	Prétraitement des caractéristiques d'excitation	47
3.1	Adaptation des niveaux et des caractéristiques	47
3.1.1	Adaptation des niveaux	47
3.1.2	Adaptation des caractéristiques	48
3.2	Modulation.....	49
3.3	Intensité acoustique.....	49
3.4	Calcul du signal d'erreur	50

4	Calcul des variables de sortie de modèle	50
4.1	Aperçu général	50
4.2	Différence de modulation.....	51
4.2.1	RmsModDiff _A	51
4.2.2	WinModDiff1 _B	52
4.2.3	AvgModDiff1 _B et AvgModDiff2 _B	52
4.3	Intensité acoustique du bruit	52
4.3.1	RmsNoiseLoud _A	53
4.3.2	RmsMissingComponents _A	53
4.3.3	RmsNoiseLoudAsym _A	53
4.3.4	AvgLinDist _A	53
4.3.5	RmsNoiseLoud _B	53
4.4	Largeur de bande.....	53
4.4.1	Pseudo-code	53
4.4.2	BandwidthRef _B et BandwidthTest _B	54
4.5	Rapport bruit/masque (NMR)	54
4.5.1	Total NMR _B	54
4.5.2	Segmental NMR _B	55
4.6	Relative Disturbed Frames _B	55
4.7	Probabilité de détection.....	55
4.7.1	Probabilité de détection maximum filtrée (MFPD _B)	56
4.7.2	Bloc distordu moyen (ADB _B).....	57
4.8	Structure harmonique de l'erreur.....	57
4.8.1	EHS _B	57
5	Moyennes	58
5.1	Calcul de la moyenne spectrale.....	58
5.1.1	Moyenne linéaire.....	58
5.2	Calcul de la moyenne temporelle.....	58
5.2.1	Moyenne linéaire.....	58
5.2.2	Moyenne quadratique	58
5.2.3	Moyenne avec fenêtrage.....	59
5.2.4	Sélection des trames	59
5.3	Moyenne sur les canaux audio	60
6	Estimation de la qualité audio de base perçue	60
6.1	Réseau neuronal artificiel.....	60
6.2	Version de base	60
6.3	Version avancée	62
7	Conformité des mises en oeuvre.....	63
7.1	Généralités	63
7.2	Sélection.....	63
7.3	Réglages pour les tests de conformité.....	64
7.4	Intervalle de tolérance acceptable	64
7.5	Éléments de tests.....	64
	Appendice 1 de l'Annexe 2 – Processus de validation.....	65
1	Généralités.....	65
2	Phase de compétition	65
3	Phase de collaboration	66

	Page	
4	Vérification.....	66
4.1	Comparaison des valeurs de SDG et de ODG.....	67
4.2	Corrélation	67
4.3	Valeurs de l'erreur absolue (AES).....	70
4.4	Comparaison des ODG et de l'intervalle de confiance.....	71
4.5	Comparaison des ODG et de l'intervalle de confiance (tolérance).....	75
5	Sélection des versions optimales du modèle.....	77
5.1	Critères de présélection fondés sur la corrélation	77
5.2	Analyse du nombre d'éléments non conformes.....	78
5.3	Analyse de la gravité des non-conformités	78
6	Conclusion.....	79
	Appendice 2 de l'Annexe 2 – Description des bases de données de référence	79
1	Introduction	79
2	Éléments par base de données	81
3	Conditions expérimentales.....	81
3.1	MPEG90	82
3.2	MPEG91	82
3.3	ITU92DI.....	82
3.4	ITU92CO	82
3.5	ITU93.....	82
3.6	MPEG95	83
3.7	EIA95	83
3.8	DB2.....	83
3.9	DB3.....	83
3.10	CRC97.....	84
4	Éléments par condition pour DB2 et DB3	84
4.1	DB2.....	84
4.2	DB3.....	86
	Glossaire	86
	Abréviations.....	87
	Références.....	88

Aperçu général

1 Introduction

La qualité du son est l'un des facteurs clés à prendre en compte lors de la conception d'un système numérique de radiodiffusion. L'introduction rapide de divers schémas de réduction du débit binaire a conduit à des efforts significatifs pour définir et affiner des procédures d'évaluations subjectives, tout simplement parce que les tests d'écoute formels étaient la seule méthode pertinente pour juger de la qualité du son. L'expérience acquise a servi de base à la Recommandation UIT-R BS.1116, qui à son tour a servi de fondement à la plupart des tests d'écoute de ce type.

Les évaluations subjectives de la qualité étant à la fois longues et coûteuses, il est nécessaire de développer une méthode de mesure objective pour obtenir une estimation de la qualité du son. Les méthodes de mesure objective traditionnelles, comme le rapport signal/bruit (S/N) ou la distorsion harmonique totale (THD) n'ont jamais apporté la preuve de leur fiabilité pour ce qui est de leur rapport à la qualité du son perçu. Les problèmes sont encore plus évidents lorsque les méthodes sont appliquées aux codecs modernes qui sont à la fois non linéaires et non stationnaires.


Ces dix dernières années ont vu l'apparition d'un certain nombre de méthodes de mesure objective de la qualité du son perçu. Mais aucune de ces méthodes n'a été totalement validée, ni, en conséquence, normalisée ou acceptée sur une grande échelle. En 1994, l'UIT-R a identifié le besoin urgent d'établir une norme dans ce domaine, et les travaux ont été lancés. Un appel à propositions a été passé et les six méthodes de mesure proposées suivantes ont été retenues; Indice de perturbation (DIX), Rapport bruit/masque (NMR), Mesure perceptuelle de la qualité du son (PAQM), PERCEVAL, Mesure perceptuelle objective (POM) et la Toolbox Approach. Ces méthodes sont décrites dans l'Appendice 4 à l'Annexe 1.

La méthode de mesure proposée dans cette Recommandation est le résultat d'un processus au cours duquel on a étudié les performances des six méthodes ci-dessus, et extrait les outils les plus prometteurs pour les intégrer à une méthode unique. La méthode recommandée a été soigneusement validée sur un certain nombre de sites d'essais. Elle s'est avérée générer des informations fiables et utiles pour de nombreuses applications. Il ne faut cependant pas oublier que la méthode de mesure objective proposée dans cette Recommandation ne remplace pas, de façon générale, un test d'écoute formel.

2 Applications

Le concept fondamental des mesures objectives avec la méthode recommandée est illustré par la Figure 1 ci-dessous.

FIGURE 1
Concept fondamental des mesures objectives



1387-01

La méthode de mesure proposée dans cette Recommandation est applicable à la plupart des types d'équipement de traitement de signaux audio, numériques et analogiques. Néanmoins, il est probable que beaucoup d'applications seront fondées sur des codecs audio.

On a identifié les 8 classes d'applications décrites dans le Tableau 1:

TABLEAU 1

Applications

	Application	Description rapide	Version
1	Evaluation de réalisations	Procédure qui permet de caractériser différentes réalisations d'équipements de traitement audio, dans de nombreux cas des codecs audio	Base/ Avancée
2	Alignement qualité perceptuelle	Procédure rapide précédant la mise en service d'une partie d'équipement ou d'un circuit	Base
3	Contrôle en ligne	Processus en continu pour surveiller une transmission audio en service	Base
4	Etat des équipements ou des connexions	Analyse détaillée d'une partie d'équipement ou d'un circuit	Avancée
5	Identification de codec	Procédure permettant d'identifier le type et la réalisation d'un codec donné	Avancée
6	Développement de codec	Procédure qui permet de caractériser les performances du codec aussi précisément que possible	Base/ Avancée
7	Planification de réseau	Procédure qui permet d'optimiser le coût et les performances d'un réseau de transmission selon des contraintes données	Base/ Avancée
8	Aide à l'évaluation subjective	Outil de sélection des matériaux critiques à intégrer à un test d'écoute	Base/ Avancée

3 Versions


Afin de parvenir à la meilleure adéquation possible avec les différentes exigences de coût et de performances, la présente Recommandation propose deux versions de la méthode de mesure objective recommandée. La version de base permet une réalisation en temps réel d'un bon rapport coût/performances, la version avancée vise à obtenir la plus grande précision possible. Selon la réalisation, cette précision supplémentaire augmente la complexité selon un facteur d'environ quatre par rapport à la version de base.

Le Tableau 1 aidera au choix de la version à utiliser pour chacune des applications.

4 Le domaine subjectif

Les essais formels d'écoute subjective, par exemple ceux fondés sur la Recommandation UIT-R BS.1116, sont précisément conçus pour parvenir à une estimation aussi fiable que possible de la qualité du son. On ne peut cependant pas espérer que le résultat d'un essai d'écoute subjectif soit le parfait reflet de la perception réelle. La Figure 2 illustre les imperfections inévitables, aussi bien dans le domaine subjectif que dans le domaine objectif.

FIGURE 2
Concepts de validation




Il est évidemment impossible de valider directement une méthode objective. Les méthodes de mesure objectives sont donc validées par rapport à des essais d'écoute subjective.

La méthode de mesure objective proposée dans la présente Recommandation est centrée sur des applications qui sont normalement évaluées dans le domaine subjectif en appliquant la Recommandation UIT-R BS.1116. On peut rapidement décrire le principe fondamental de cette méthode d'essai particulière de la façon suivante: l'auditeur a le choix entre trois sources («A», «B», «C»). La source «A» est toujours le Signal de référence connu. Le Signal de référence masqué et le Signal testé sont disponibles simultanément mais sont, selon l'essai, affectés de façon aléatoire à «B» ou à «C».

On demande à l'auditeur d'évaluer les dégradations en «B» par rapport à «A», et en «C» par rapport à «A», selon l'échelle de dégradations continue à cinq notes. Une des sources, «B» ou «C», ne doit pas pouvoir être discernée de la source «A»; l'autre peut révéler des dégradations. Toute différence perçue entre la référence et l'autre source doit être interprétée comme étant une dégradation. On n'utilise normalement qu'un seul attribut, la «Qualité audio de base», défini comme un attribut global qui intègre toutes les différences détectées entre le Signal de référence et le Signal testé.

Cette échelle d'évaluation est continue et présente des «points de référence» qui proviennent de l'échelle de dégradation à cinq notes proposée dans la Recommandation UIT-R BS.562 et représentée ci-dessous.

FIGURE 3
Echelle de dégradation à cinq notes de l'UIT-R



1387-03

L'analyse des résultats d'un essai d'écoute subjective est généralement fondée sur la note différentielle subjective (SDG), définie par l'équation:

$$SDG = \text{Note}_{\text{Signal testé}} - \text{Note}_{\text{Signal de référence}}$$

Idéalement, les valeurs de SDG doivent être situées dans une fourchette entre 0 et -4, où 0 correspond à une dégradation imperceptible et -4 à une dégradation jugée comme très gênante.

5 Résolution et précision

La note différentielle objective (ODG) est la variable de sortie de la méthode de mesure objective; elle correspond à la SDG dans le domaine subjectif. La résolution de l'ODG est limitée à une décimale. Il faut néanmoins être prudent et ne pas croire, en règle générale, qu'une différence d'un dixième entre deux paires quelconques d'ODG soit significative. Il en va de même lorsque l'on étudie les résultats d'un essai d'écoute subjective.

La précision de la méthode de mesure objective ne peut être décrite par un chiffre unique. Il faut prendre en compte un certain nombre d'indices de qualité, dont la corrélation entre les SDG et les ODG. Il est important de savoir qu'il n'y a pas de garantie que cette corrélation dépassera une valeur prédéfinie. Les performances de la méthode de mesure seront susceptibles de varier selon, par exemple, le type et le niveau de la dégradation introduite.

Le nombre de valeurs non conformes est également intéressant. Une valeur non conforme est une valeur mesurée qui n'entre pas dans une fourchette de tolérance prédéfinie. Selon les exigences de l'utilisateur, la méthode de mesure devra fournir la plus grande précision possible dans le haut de l'échelle (c'est-à-dire une qualité audio élevée). En conséquence, on acceptera que la précision soit moindre dans les parties médiane et inférieure de l'échelle.

La corrélation offre normalement une bonne estimation de la précision de la méthode de mesure objective, mais il faut garder à l'esprit qu'une valeur de corrélation relativement élevée peut cacher une performance inacceptable (du point de vue des valeurs non conformes) d'une méthode de mesure.

Le troisième chiffre intéressant utilisé lors du processus de validation est la valeur de l'erreur absolue (AES), qui est le reflet de la moyenne de la relation entre la taille de l'intervalle de confiance de la SDG et l'écart entre SDG et ODG.

On trouvera dans l'Appendice 1 de l'Annexe 2 plus de détails concernant les performances attendues de la méthode de mesure et les performances lors du processus de validation.

6 Exigences et limitations

Le signal provenant du Système testé et le Signal de référence doivent être synchronisés avec une précision de 24 échantillons sur toute la durée de la mesure. Le mécanisme de synchronisation ne fait pas partie de cette Recommandation parce qu'il variera selon la réalisation.

APPENDICE 1 DE L'ANNEXE 1

Applications

1 Généralités

Cet Appendice contient les définitions et exigences spécifiques des principales applications auxquelles est destinée cette Recommandation d'une méthode de mesure objective de la qualité du son perçu.

Certaines applications demandent une mise en œuvre en temps réel de la méthode de mesure objective; pour d'autres applications, une mesure en temps réel n'est pas nécessaire. Pour les mises en œuvre en temps réel, nous recommandons que le retard maximum dans l'appareil de mesure n'excède pas 200 ms; un retard de plus de 1 s n'est pas acceptable.

De plus, il convient de distinguer entre les mesures en ligne et les mesures hors ligne. Lors des mesures hors ligne, la procédure de mesure a un accès total à l'appareil ou à la connexion; les mesures en ligne impliquent qu'un programme est en cours et qu'il ne doit pas être interrompu par la mesure.

2 Applications principales

2.1 Evaluation des réalisations

Les radiodiffuseurs, opérateurs de réseaux, et autres, ont besoin d'évaluer diverses réalisations d'équipements, particulièrement de codecs audio, lors du choix de l'équipement à acheter ou lors d'essais de réception.

Pour ces types d'applications, une haute précision est nécessaire, particulièrement pour évaluer les petites dégradations et classer correctement différentes réalisations. En ce qui concerne les variables de sortie, une sortie simple comme l'ODG suffit aux utilisateurs, mais les développeurs de codecs audio pourront effectuer une analyse plus profonde avec un ensemble adapté de variables de sortie de modèle (MOV).

On peut utiliser les deux versions du modèle, mais nous recommandons la version avancée.

2.2 Alignement qualité perceptuelle

Il s'agit d'une procédure rapide lancée avant la mise en service d'une partie d'équipement ou d'un circuit. Le but en est de contrôler la fonctionnalité et la qualité. L'équipement de mesure sera géré par le personnel d'exploitation. Tous types de distorsion peuvent être présents.

La mesure doit se faire en temps réel. On peut utiliser des signaux d'essai ou des signaux audio prédéfinis. Les ODG doivent être correctement affichées et données au moins deux fois par seconde ou, si l'on utilise un signal d'essai spécial, directement à la fin du signal d'essai.

La version de base suffit.

2.3 Contrôle en ligne

Il s'agit d'une procédure en continu, pendant une transmission radiophonique. Le programme ne doit pas être interrompu par la procédure de mesure. On doit donc utiliser pour la mesure soit le signal du programme lui-même, soit un fragment audio prédéfini. Ce dernier peut être un signal de la station ou un jingle. L'équipement de mesure sera géré par le personnel d'exploitation.

La mesure doit se faire en temps réel. Les ODG doivent être correctement affichées et données au moins deux fois par seconde, ou directement à la fin du signal prédéfini. L'affichage des MOV n'est pas nécessaire.

La version de base suffit.

2.4 Etat des équipements ou des connexions

Pour assurer la fonctionnalité des connexions ou des équipements audio, un contrôle complet de la qualité est nécessaire de temps à autre. Contrairement au contrôle en ligne ou à l'alignement perceptuel, cette application nécessite le contrôle de plusieurs paramètres techniques.

Le système de mesure devra fournir des informations détaillées sur l'influence des états des équipements ou des connexions sur la qualité du son perçu en affichant le jeu complet de MOV en plus des ODG. La mesure en temps réel n'est pas nécessaire.

La version avancée est recommandée.

2.5 Identification des codecs

Pour identifier les codecs (différents algorithmes ou différentes mises en œuvre du même algorithme), le système de mesure doit pouvoir mémoriser, récupérer et comparer différentes caractéristiques. Une similarité entre les caractéristiques peut être interprétée comme une mesure de la similarité de différentes mises en œuvre de codecs. On utilise cette procédure pour identifier le type et la mise en œuvre d'un codec particulier.

Le système de mesure doit enregistrer autant d'informations que possible sur les caractéristiques. Les ODG à elles seules peuvent ne pas fournir assez d'informations.

La version de base suffit, même si une mesure en temps réel n'est pas nécessaire.

NOTE – On est peu familiarisé avec la méthode recommandée. De plus, aucune mesure de similarité entre les caractéristiques n'est encore définie.

2.6 Développement des codecs

Pour cette application, la méthode de mesure doit déterminer la performance du codec testé de manière aussi précise et détaillée que possible, particulièrement pour les faibles dégradations.

Le contrôle continu nécessite un traitement en temps réel qui n'est pas forcément supporté par la version avancée. Mais, en ce qui concerne les faibles dégradations et pour obtenir des informations détaillées, il faut utiliser la version avancée. Le système de mesure doit pouvoir afficher les valeurs de sortie à la même vitesse que celle à laquelle elles sont calculées. Il faut avoir un accès direct à l'historique des sorties sur une durée de 4 s.

Nous recommandons d'utiliser la version avancée. Néanmoins, pour des mesures en temps réel, la version de base suffit. Il faut effectuer une analyse aussi bien en temps réel, qu'en hors ligne et trame par trame. Toute distorsion grave devra être indiquée, par exemple par affichage des valeurs de crêtes. Il faut avoir accès à l'ensemble des MOV.

2.7 Planification des réseaux

La planification des réseaux nécessite une évaluation de la qualité espérée à différents moments du processus de planification. Pour étudier différentes configurations afin d'optimiser la qualité du son, on peut procéder à une simulation logicielle des composants du réseau qui permettra d'associer différentes étapes de traitement du son. Ultérieurement, les composants réels du traitement du son pourront être testés dans la configuration choisie.

La planification des réseaux est effectuée par des ingénieurs de système qui doivent pouvoir récupérer des informations détaillées sur l'influence des caractéristiques du réseau sur la qualité du son. La classification des différentes configurations réseaux possibles devra être fondée sur un ensemble de MOV adapté à l'application spécifique du réseau. Ainsi, un affichage des seules ODG n'est pas suffisant. Une évaluation dans cette application ne nécessite pas une mesure en temps réel.

On peut utiliser les deux versions du modèle, mais la version avancée est recommandée.

2.8 Aides à l'évaluation subjective

La méthode de mesure objective fournit un outil qui permet de choisir le matériau sonore critique à utiliser pour les essais d'écoute subjectifs. On peut utiliser l'ensemble des MOV pour définir ce matériau.

Il faut obtenir la précision la plus haute possible; la version avancée est donc recommandée. Mais il faut effectuer des mesures en temps réel afin de réduire le temps nécessaire au choix des matériaux critiques.

2.9 Résumé des applications

Le Tableau 2 résume les exigences relatives à la méthode de mesure pour les principales applications.

TABLEAU 2

Exigences relatives à la méthode de mesure

	Application	Catégorie	Temps réel	Min, ROV ¹ [Hz]	En ligne/ Hors ligne	Version du modèle
1	Evaluation de réalisations	Diagnostic	Non	–	Hors ligne	Les deux
2	Alignement qualité perceptuelle	Exploitation	Oui/Non	2	Hors ligne	Base
3	Contrôle en ligne	Exploitation	Oui	2	En ligne	Base
4	Etat des équipements ou des connexions	Diagnostic	Oui/Non	–	En ligne/ Hors ligne	Avancée
5	Identification de codec	Diagnostic	Non	–	Hors ligne	Les deux
6	Développement de codec	Développement	Oui/Non	–	Hors ligne	Les deux
7	Planification de réseau	Développement	Oui/Non	–	Hors ligne	Les deux
8	Aide à l'évaluation subjective	Développement	Oui/Non	–	Hors ligne	Avancée

3 Les signaux d'essais

On distingue deux groupes de signaux d'essais: les signaux naturels et les signaux synthétisés. La liste des signaux d'essais naturels fournie ici est constituée de séquences sonores critiques déjà utilisées, par l'UIT-R et d'autres organisations, lors de tests d'écoute, pour l'évaluation de la qualité du son. Ces signaux doivent être disponibles sur le site de transmission et sur le site de mesure. Le système de mesure doit donc avoir une mémoire.

¹ Débit des valeurs de sorties (par seconde).

Les signaux synthétisés sont définis mathématiquement et peuvent être transformés de façon contrôlée. Ces signaux peuvent être générés sur le site de transmission et sur le site de mesure. Il n'y a pas besoin de mémoire supplémentaire dans le système de mesure. Du fait de la nature de ces signaux, il est difficile, voire impossible, de dériver pour eux des classifications subjectives. En conséquence, pour ces signaux, la méthode de mesure n'a pas été validée par comparaison avec les résultats subjectifs.

3.1 Sélection de signaux d'essais naturels

On trouvera dans le Tableau 3 une liste de sous-ensembles de signaux d'essais utilisés lors de la procédure de vérification qui a conduit à la présente Recommandation. Le type d'artefacts révélés par ces signaux codec à faible débit binaire est également indiqué.

TABLEAU 3

Liste de sous-ensembles de signaux d'essais

N°	Élément	Nom fichier	Remarques
1	Castagnettes	cas	1
2	Clarinette	cla	2
3	Claves	clv	1
4	Flûte	flu	2
5	Glockenspiel	glo	1 & 2 & 5
6	Clavecin	hrp	1 & 2 & 4
7	Timbale	ket	1
8	Marimba	mar	1
9	Piano Schubert	pia	2
10	Diapason	pip	4
11	Ry Cooder	ryc	2 & 4
12	Saxophone	sax	2
13	Cornemuse	sb1	2 & 4 & 5
14	Voix de femme Angl.	sfe	3
15	Voix d'homme Angl.	sme	3
16	Voix d'homme Allem.	smg	3
17	Caisse claire	sna	1
18	Soprano Mozart	sop	4
19	Tambourin	tam	1
20	Trompette	tpt	2
21	Triangle	tri	1 & 2 & 5
22	Tuba	tub	2
23	Susanne Vega	veg	3 & 4
24	Xylophone	xyl	1 & 2

Notes:

- 1) Transitoires: sensibilité au préécho, rémanence du bruit dans le domaine temporel.
- 2) Structure tonale: sensibilité au bruit, rugosité.
- 3) Voix naturelle (association critique de parties tonales et d'attaques): sensibilité à la distorsion, dégradation des attaques.
- 4) Son complexe: soumet le Système testé à de fortes contraintes.
- 5) Grande largeur de bande: soumet le Système testé à de fortes contraintes, perte des fréquences élevées, bruits de fréquence élevée modulés par le programme.

3.2 Durée

La durée d'un signal d'essai naturel doit être à peu près la même que lors d'un test d'écoute. Cette durée est typiquement de l'ordre de 10 à 20 s. Il est très probable que la partie critique du signal d'essai, qui dévoile la plupart des artefacts, est limitée à une brève fraction de cette durée.

La durée des signaux d'essais synthétisés doit être suffisante pour soumettre le codec testé à de fortes contraintes; ce codec peut comporter un buffer de signal sonore codé. Si l'on considère la longueur de ces tampons et les constantes temporelles de la méthode de mesure, la durée de chaque séquence d'un élément de test doit être supérieure à 500 ms. La durée peut être limitée à cette valeur faible parce que ces signaux ne seront pas utilisés lors de tests d'écoute subjectifs.

4 Synchronisation

Pour la procédure de mesure, le Signal testé et le Signal de référence devront être synchronisés dans le temps. Cette remarque s'applique aux signaux d'essai naturels et synthétisés.

5 Droits de reproduction

Les signaux d'essai du Tableau 3 ne peuvent être utilisés hors droits de reproduction qu'aux fins de mesure en association avec la méthode de mesure objective, décrite dans l'Annexe 2 de cette Recommandation.

NOTE – L'exonération des droits de reproduction doit être obtenue pour toutes les séquences, essentiellement auprès de l'UER (disque EBU SQAM).

APPENDICE 2 DE L'ANNEXE 1

Variables de sortie

1 Introduction

La méthode de mesure objective décrite dans cette Recommandation mesure la qualité du son et propose une valeur censée correspondre à la qualité du son perçu. Cette méthode de mesure modélise les propriétés fondamentales du système auditif. De nombreux stades intermédiaires modélisent les effets physiologiques et psychoacoustiques.

Ces valeurs intermédiaires peuvent servir à déterminer les artefacts. Ces paramètres sont les variables de sortie de modèle (MOV). La dernière étape du modèle de mesure combine les valeurs de MOV pour obtenir une valeur de sortie unique qui correspond directement au résultat espéré d'une évaluation de la qualité subjective.

2 Les variables de sortie de modèle

Le Tableau 4 présente une description des MOV utilisées pour prédire les notes différentielles objectives. Les indices_A proviennent du banc de filtres du modèle, les indices_B du modèle FFT. Les notes différentielles objectives sont prédites, soit uniquement à partir de la partie FFT (version de base), soit d'une association de la partie FFT et du banc de filtres (version avancée). La moyenne est toujours calculée par rapport au temps.

3 Qualité audio de base

Le paramètre le mieux connu à partir des essais d'écoute subjective est la qualité audio de base (BAQ). La BAQ est la mesure d'une note différentielle subjective (SDG) qui est la différence entre le niveau de la référence et le niveau du Signal testé dans un test subjectif². La SDG a normalement une valeur négative. On appelle note différentielle objective (ODG) le paramètre de sortie du modèle correspondant. La fonction de passage des MOV à une ODG est fondée sur un grand nombre d'éléments d'essai fiables, voir l'Annexe 2, Appendice 2.

² Voir la Recommandation UIT-R BS.1116.

TABLEAU 4

Description des variables de sortie de modèle

Variables de sortie de modèle	Description
$WinModDiff_B$	<i>Différence moyenne de modulation après fenêtrage (enveloppes) entre le Signal de référence et le Signal testé</i>
$AvgModDiff1_B$	<i>Différence de modulation moyenne</i>
$AvgModDiff2_B$	<i>Différence de modulation moyenne avec prise en compte particulière des modulations introduites et des variations de modulation quand la référence contient peu ou pas de modulations</i>
$RmsModDiff_A$	<i>Valeur Rms de la différence de modulation</i>
$RmsMissingComponents_A$	<i>Valeur Rms de l'intensité du bruit des composantes de fréquences manquantes, (valeur utilisée dans $RmsNoiseLoudAsym_A$)</i>
$RmsNoiseLoud_B$	<i>Valeur Rms de l'intensité moyenne du bruit avec prise en compte particulière des composantes introduites</i>
$RmsNoiseLoudAsym_A$	<i>$RmsNoiseLoud_A + 0,5RmsMissingComponents_A$</i>
$AvgLinDist_A$	<i>Mesure des distorsions linéaires moyennes avec une pondération plus importante dans les bandes de fréquences élevées</i>
$BandwidthRef_B$	<i>Largeur de bande du Signal de référence</i>
$BandwidthTest_B$	<i>Largeur de bande du signal de sortie du Système testé</i>
$TotNMR_B$	<i>Logarithme de la moyenne du rapport bruit/masque total</i>
$RelDistFrames_B$	<i>Fraction relative des trames pour lesquelles au moins une bande de fréquences contient une composante de bruit significative</i>
$AvgSegmNMR_B$	<i>Moyenne par segmentation du logarithme du rapport bruit/masque</i>
$MFPD_B$	<i>Probabilité maximum de détection après filtre passe-bas</i>
ADB_B	<i>Moyenne de blocs distordus, logarithme du rapport de la distorsion totale/nombre total de trames fortement distordues</i>
EHS_B	<i>Structure harmonique de l'erreur dans le temps</i>

L'ODG est le paramètre mesuré de façon objective qui correspond à la qualité perçue de façon subjective. La tâche d'un auditeur lors d'un essai d'écoute étant d'évaluer la BAQ d'un élément d'essai, l'ODG est également une mesure de la BAQ.

4 Marge de codage

La marge de codage (CM), description des artefacts inaudibles, est un paramètre qui pourrait s'avérer intéressant dans le futur. On évalue la marge de codage subjective (SCM) en amplifiant les artefacts jusqu'à ce qu'ils deviennent audibles par l'auditeur. La SCM définit l'écart jusqu'au seuil d'audibilité des artefacts.

Pour déterminer ce seuil, on doit amplifier ou atténuer les artefacts lors du test d'écoute. On utilise la méthode des différences. Le signal de différence entre l'original synchrone dans le temps et le signal codé est amplifié et ajouté au signal original. La meilleure méthode de détection du seuil d'audibilité est la méthode du choix forcé. On obtient la SCM en faisant la moyenne des valeurs de seuil pour l'amplification ou l'atténuation obtenues auprès des auditeurs. Des valeurs négatives de CM indiquent des artefacts audibles, des valeurs positives indiquent des artefacts inaudibles. Contrairement à la BAQ, la marge de codage est la mesure du moment (du niveau) où les artefacts deviennent audibles et non de la gêne qu'ils génèrent. On trouvera en [Feiten, mars 1997] la définition et la validation de la méthode de mesure de la SCM.

La marge de codage objective (OCM) provient elle aussi des MOV. A l'heure actuelle, on n'a évalué que peu d'éléments de test pour la marge de codage objective. La schématisation des OCM du modèle de la présente Recommandation n'a pas encore fait l'objet de recherches.

5 Exigences des utilisateurs

Les exigences des utilisateurs en ce qui concerne les variables de sortie de la méthode de mesure varient selon l'application. Pour certaines applications, par exemple, les numéros 2 et 3 (voir l'Appendice 1 de l'Annexe 1), la mesure fait partie d'une procédure d'exploitation. Il est très important dans ce cas que le résultat de la méthode soit facile à lire et à interpréter par des personnes n'ayant pas de connaissances approfondies de la technique de mesure. Le meilleur moyen est que la méthode ne donne qu'**une seule valeur** qui corresponde à la qualité du son perçu.

Cette remarque peut concerner d'autres applications, par exemple, les Applications 1 et 4. Néanmoins, pour ces applications, ainsi que pour les Applications 5-8, des variables de sortie plus sophistiquées pourront représenter un avantage pour les utilisateurs ayant une connaissance plus approfondie des mécanismes de la méthode de mesure.

APPENDICE 3 DE L'ANNEXE 1


Présentation du modèle

Selon la Recommandation UIT-R BS.1116, on obtient une SDG pour un élément de test sonore lors d'un test d'écoute, et la SDG moyenne sur un certain nombre d'auditeurs représente la qualité subjective de l'élément. L'élément peut contenir divers types de distorsions du son, les variations de la qualité sont donc intégrés dans le temps. Ainsi, pour prédire les SDG sur la base de mesures physiques, il faut un modèle précis du système auditif périphérique ainsi que des aspects cognitifs du jugement de la qualité sonore.

Le modèle recommandé pour la mesure objective produit un certain nombre de variables de sortie de modèle (MOV) fondées sur des comparaisons entre le Signal de référence et le Signal testé. Ces MOV sont transformées en une ODG avec une technique d'optimisation qui réduit le carré de la différence entre la distribution des ODG et la distribution correspondante des moyennes de SDG pour un ensemble de données suffisamment important.

Il y a deux variations sur le modèle – une version fondée sur la DFT que l'on peut utiliser pour le contrôle en temps réel, et une version, fondée sur un banc de filtres et la DFT, qui donnent des résultats plus précis. La version DFT est la version de base, la version avancée y associe le banc de filtres.

La Figure 4 représente la structure haute des deux versions.



1 Traitement du son

Comme lors des essais d'écoute subjective, la qualité du signal testé est jugée par rapport au Signal de référence. Le Signal de référence et le Signal testé (signaux mono ou stéréo) sont transformés en une représentation psychoacoustique. On compare ces représentations afin d'obtenir une ODG. Ces opérations sont effectuées lors des étapes du traitement indiquées sur la Figure 4.

1.1 Paramètres définis par l'utilisateur

La méthode de mesure requiert que le niveau d'écoute soit considéré comme étant un paramètre. Ainsi, l'utilisateur doit préciser un niveau de pression acoustique en dB SPL produit par une onde sinusoïdale pleine échelle de 1 019,5 Hz. Si le niveau d'écoute exact est inconnu, il est recommandé de supposer un niveau d'écoute de 92 dB SPL.

1.2 Modèle psychoacoustique

Le modèle psychoacoustique transforme les trames successives du signal en une représentation sur la membrane basilaire. Ce processus commence avec une DFT et un banc de filtres. La DFT transforme les données dans le domaine des fréquences, et le résultat est transformé de l'échelle des fréquences en échelle des hauteurs sonores, équivalent psychoacoustique de la fréquence. Dans le modèle à banc de filtres, le passage des fréquences aux hauteurs sonores est pris directement en compte par les largeurs de bandes et l'espacement des filtres passe-bande.

On utilise deux concepts différents pour parvenir à un masquage simultané. Certaines MOV sont calculées avec le *concept de seuil de masquage*, d'autres sont fondées sur une *comparaison des représentations internes*. Le premier concept calcule directement un seuil de masquage par l'intermédiaire de fonctions de masquage psychophysiques. Les MOV sont fondées sur l'écart entre le signal d'erreur physique et ce seuil de masquage. Dans le concept de comparaison des représentations internes, les énergies du Signal testé et du Signal de référence sont étendues aux hauteurs sonores adjacentes afin d'obtenir des schémas d'excitation. Les MOV sont fondées sur la comparaison de ces schémas d'excitation. Le masquage non simultané est mis en œuvre par rémanence des représentations du signal dans le temps.

Le seuil absolu est modélisé par application d'une fonction de pondération dépendant de la fréquence et par ajout, aux schémas d'excitation, d'un décalage dépendant de la fréquence. Ce seuil est une approximation de la pression audible minimum [ISO 389-7, *Acoustics – Reference zero for the calibration of audiometric equipment – Part 7: Reference threshold of hearing under free-field and diffuse-field listening conditions*, 1996].

Les résultats principaux du modèle psychoacoustique sont l'excitation et le seuil de masquage en fonction du temps et de la fréquence. Les résultats du modèle à plusieurs niveaux sont disponibles pour la suite du processus.

1.3 Modèle cognitif

Le modèle cognitif condense les informations à partir d'une séquence de trames produite par le modèle psychoacoustique. Les sources d'informations les plus importantes pour des mesures de qualité sont les différences entre le Signal de référence et le Signal testé dans le domaine fréquentiel et celui des hauteurs sonores. Dans le domaine fréquentiel, on mesure les largeurs de bandes spectrales des deux signaux, ainsi que la structure harmonique de l'erreur. Dans le domaine des hauteurs sonores, les mesures de l'erreur sont dérivées de la modulation de l'enveloppe de l'excitation, ainsi que de l'amplitude de l'excitation.

Les caractéristiques calculées sont pondérées, de façon à ce que leur association donne une ODG suffisamment proche de la SDG pour une certaine distorsion du son étudiée. La version de base utilise 11 caractéristiques pour produire une ODG, la version avancée en utilise 5. L'optimisation a été obtenue grâce à l'algorithme d'apprentissage d'un réseau neuronal à propagation rétrograde (voir l'Annexe 2, § 6). Les données d'apprentissage comprennent la totalité des bases de données 1 et 2, et une partie de la base de données 3. Les données d'essai de généralisation ont été obtenues à partir de la fin de la base de données 3 et de toutes les données CRC97 (voir l'Appendice 2 de l'Annexe 2).

APPENDICE 4 DE L'ANNEXE 1

Principes et caractéristiques des méthodes de mesure objective de la qualité perceptuelle du son

1 Introduction et historique

La transmission numérique et le stockage des signaux audio sont de plus en plus fondés sur des algorithmes de réduction des données, qui sont adaptés aux propriétés du système auditif humain et reposent tout particulièrement sur des effets de masquage. Ces algorithmes ne visent pas essentiellement à réduire les distorsions, mais plutôt à gérer ces distorsions de façon à ce qu'elles soient le moins audibles possible. La qualité de ces encodeurs perceptuels ne peut plus être évaluée par les méthodes de mesure conventionnelles, qui déterminent normalement la valeur générale de la distorsion. Pour illustrer ces limitations, on cite souvent ce que l'on appelle le miracle des 13 dB: un bruit ajouté ayant une structure spectrale adaptée à celle du signal audio quasiment inaudible même si le rapport signal/bruit non pondéré qui en résulte descend jusqu'à 13 dB.

C'est pour cette raison que les évaluations des codecs perceptuels nécessitent des essais d'écoute afin d'évaluer la qualité du son. Une bonne fiabilité et une bonne répétabilité des essais d'écoute demandent beaucoup de temps et de travail.

Ces problèmes peuvent être surmontés grâce à des schémas de mesure objective qui intègrent le système auditif humain. C'est en 1979 que Schroeder, Atal et Hall publient cette idée [Schroeder et autres, 1979]. Leur article, qui concerne essentiellement le codage de la parole, décrit la procédure de la méthode de mesure «Intensité acoustique du bruit (NL, Noise Loudness)».

Dans cet article, les auteurs évaluent l'intensité perçue du signal de bruit du codec de la parole, c'est-à-dire la différence entre le signal d'entrée et le signal de sortie, pour chaque trame temporelle d'environ 20 ms. Si le signal de bruit est totalement masqué, l'intensité perçue est zéro. Un masquage partiel réduit l'intensité du signal de bruit non masqué. Le seuil de masquage utilisé est optimisé pour le bruit qui masque le son et on calcule pour chaque trame la dégradation finale de la parole. Il n'y a pas de calcul d'un résumé de la qualité totale d'un échantillon de parole.

En 1984, Karjalainen publie sa méthode de mesure «Différence auditive spectrale (ASD, Auditory Spectral Difference)» [Karjalainen, 1985]. Il reprend plusieurs idées de Schroeder, Atal et Hall mais remplace l'analyse fondée sur la trame par un banc de filtres qui se recouvrent partiellement, change la méthode d'intégration du seuil absolu et ajoute un modèle de masquage temporel. Les deux signaux d'entrée dans le système de mesure sont traités exactement de la même façon, afin de produire une sorte de représentation interne. Ces représentations internes sont comparées les unes aux autres pour expliquer les différences perçues entre le signal d'entrée et le signal de sortie d'un schéma de codage de la parole. Il n'y a pas de calcul d'un résumé de la qualité totale d'un échantillon de parole. La résolution temporelle de ASD est mieux adaptée aux propriétés du système auditif humain, mais augmente la complexité de l'algorithme.

En 1987, Brandenburg publie la méthode de mesure «Rapport bruit/masque (NMR)» [Brandenburg, 1987], destiné à être un outil de développement de schémas de codage du son. La complexité de ce schéma est moindre que celle de NL: on calcule l'étalement sur les bandes perceptuelles avec une fonction d'étalement conçue comme une courbe du pire cas. Le seuil utilisé après masquage est optimisé pour le son qui masque le bruit. Il ajoute un schéma simple de modélisation du postmasquage et plusieurs méthodes d'évaluation de la qualité perçue d'extraits sonores plus longs. Ce schéma sera le premier à être mis en application dans des matériels de mesure en temps réel.

En 1989, Moore et Glasberg [Moore, 1989] présentent un modèle perceptuel mais ne proposent pas de méthode pour juger de la qualité perçue de signaux sonores dégradés.

2 Structure générale des méthodes de mesure objective de la qualité perceptuelle du son

Tous les schémas de mesure perceptuelle fonctionnent avec deux signaux d'entrée: l'un est le Signal de référence (REF), l'autre le Signal testé (SUT). Dans les cas où la référence ne peut être transmise à l'équipement de mesure, mais si ce signal est connu, le Signal de référence peut être une référence interne mémorisée dans l'équipement de mesure. Il est essentiel que les deux signaux soient temporellement alignés.


Il existe deux manières d'intégrer la psychoacoustique dans les schémas de mesure. La première est très proche de la structure des schémas de codage du son: on utilise le Signal de référence pour calculer une estimation du seuil de masquage réel (voir ci-dessous). La différence entre le Signal testé et le Signal de référence est alors comparée à ce seuil de masquage. On appelle cette méthode «concept de seuil de masquage»; elle est utilisée dans NL et NMR. On peut calculer la différence entre les signaux d'entrée soit dans le domaine temporel, soit comme étant la différence entre les spectres d'énergie de courte durée. Cette dernière méthode offre une meilleure protection contre les erreurs d'alignement temporel mais réduit la résolution temporelle. La différence dans le domaine temporel est généralement trop sensible aux distorsions de phase; c'est pourquoi on ne l'utilise plus.

La seconde méthode est plus proche des processus physiologiques du système auditif humain: on calcule une représentation interne du Signal de référence et du Signal testé. Cette représentation interne est une estimation de l'information mise à la disposition du cerveau humain pour comparer les signaux. On appelle cette méthode «comparaison des représentations internes»; elle est utilisée dans ASD.

3 Considérations psychoacoustiques et cognitives

Ce paragraphe présente les propriétés du système auditif humain les plus importantes en ce qui concerne l'évaluation de la qualité perçue des signaux sonores. Le point le plus important est la méthode de modélisation de ces propriétés.

FIGURE 5
Concepts psychoacoustiques utilisés dans les différentes approches
des schémas de mesure perceptuelle



1387-05

3.1 Caractéristique de transfert par l'oreille externe et par l'oreille moyenne

Les signaux sonores doivent en général passer par l'oreille externe et par l'oreille moyenne avant d'atteindre l'oreille interne où ont lieu les processus de détection et d'analyse du son. L'oreille externe et l'oreille moyenne ont une fonction de filtrage passe-bande du signal d'entrée. Le bruit présent dans le nerf auditif, et le bruit causé par la circulation sanguine, sont ajoutés au signal d'entrée. L'amplitude de ce bruit décroît dans les basses fréquences. La fonction de transfert par l'oreille externe et par l'oreille moyenne et les bruits internes limitent la capacité à détecter les signaux sonores ténus, et ont une influence essentielle sur le seuil auditif absolu.

3.2 Echelles perceptuelles des fréquences

Dans l'oreille humaine, les récepteurs de la pression sonore sont les cils, situés dans l'oreille interne, plus précisément dans la cochlée. Dans la cochlée a lieu une transformation des fréquences en positions. La position de l'excitation maximum dépend de la fréquence du signal d'entrée. Chaque cil à une position donnée dans la cochlée est responsable d'une partie de l'échelle des fréquences; les différentes parties se recouvrent partiellement. L'impression perceptuelle de la hauteur du son est liée à la distance constante entre les cils.

Selon les expériences psychoacoustiques, on a découvert différentes fonctions de transformation de la fréquence en hauteur sonore:

on trouvera en [Zwicker et Feldtkeller, 1967] un tableau qui partage l'échelle des fréquences en Hz en 24 bandes qui ne se recouvrent pas, les bandes critiques. On trouvera dans le Tableau 6 les fréquences limites supérieures de ces bandes. Ce tableau contient également une définition de l'échelle de Bark: 1 Bark correspond à 100 Hz, 24 Bark correspondent à 15 000 Hz.

TABLEAU 6

Echelle des bandes critiques définie par Zwicker

Bande critique	1	2	3	4	5	6	7	8	9	10	11	12
Fréquence limite supérieure [Hz]	100	200	300	400	510	630	770	920	1 080	1 270	1 480	1 720
Bande critique	13	14	15	16	17	18	19	20	21	22	23	24
Fréquence limite supérieure [Hz]	2 000	2 320	2 700	3 150	3 700	4 400	5 300	6 400	7 700	9 500	12 000	15 500


On a dans le passé trouvé plusieurs approximations de l'échelle de Bark. On trouvera en [Cohen et Fielder, 1992] une étude détaillée des différentes échelles. Dans le contexte de la mesure objective de la qualité du son perçu, c'est avec l'échelle de Bark que l'on obtient les meilleurs résultats.

3.3 Excitation

Chaque cil réagit à une gamme de fréquences que l'on peut décrire comme une caractéristique de filtre. C'est sur une échelle perceptuelle telle que décrite ci-dessus que l'on peut le mieux exprimer la pente des filtres. Sur une telle échelle, la forme des filtres est quasiment indépendante de la fréquence centrale. La pente inférieure de l'excitation est indépendante du niveau L du signal d'entrée (environ 27 dB/Bark). La pente supérieure est plus accentuée pour les niveaux bas que pour les niveaux élevés du signal d'entrée (-5 à -30 dB/Bark). Cette caractéristique de pente provient d'un mécanisme de feed-back entre deux types différents de cils, et il faut un certain temps pour qu'elle se stabilise. La meilleure résolution de fréquences auditives est donc atteinte avec des signaux stationnaires plusieurs millisecondes après le début du signal. Les caractéristiques d'excitation de signaux constitués de plusieurs composantes s'ajoutent de façon non linéaire.

FIGURE 6

Dépendances de l'excitation aux niveaux selon Terhardt [1979]



Après exposition à un signal, les cils et le traitement neuronal ont besoin d'un certain temps pour recouvrer toute leur sensibilité. La durée de ce processus de récupération dépend du niveau et de la durée du signal et peut durer jusqu'à plusieurs centaines de millisecondes. Les signaux de forte intensité sont traités plus rapidement que les signaux de faible intensité entre les cils et le cerveau. Le début d'un signal fort peut donc masquer un signal antérieur plus faible.

L'échelle ERB [Moore, 1986] propose une autre approche d'un modèle d'excitation qui utilise les filtres ROEX [Moore, 1986]. Dans le contexte de la mesure objective de la qualité du son perçu, on a obtenu les meilleurs résultats avec les modèles fondés sur [Zwicker y Feldtkeller, 1967] et [Terhardt, 1979].


3.4 Détection

Les excitations des différents signaux sonores sont transmises au cerveau. Il existe trois types de mémoire qui diffèrent selon le degré de précision des détails et la durée pendant laquelle l'information est présente: une mémoire à long terme, une mémoire à court terme et une mémoire à ultra court terme. Dans le contexte des essais d'écoute, ce sont les mémoires à ultra court terme qui ont le rôle le plus important. La plupart des détails d'un signal sont conservés en mémoire si la durée de l'extrait sonore est inférieure à 5 à 8 s, selon l'auditeur et l'extrait sonore. Ce phénomène est pris en compte dans la procédure d'évaluation définie dans la Recommandation UIT-R BS.1116 où les sujets des essais peuvent choisir d'écouter de façon plus précise de toutes petites parties d'un extrait sonore. Au niveau du seuil de détection, la probabilité de détection est de 50%. De part et d'autre du seuil, la probabilité de détection des différences passe lentement de 0% à 100%.

La différence de niveau tout juste audible (JNLD, just-noticeable level difference) est le seuil de détection des différences de niveau. La JNLD subit l'influence du niveau des signaux d'entrée. Pour des signaux faibles, la détection demande de grandes différences (niveau: 20 dB SPL, JNLD: 0,75 dB). Pour les signaux de forte intensité la sensibilité aux légères différences est beaucoup plus importante (niveau: 80 dB SPL, JNLD: 0,2 dB). Ces chiffres sont fondés sur des expériences en modulation d'amplitude.

FIGURE 7

Principe de la probabilité de détection



1387-07

3.5 Masquage

Un signal parfaitement audible lorsqu'il est isolé peut être complètement inaudible en présence d'un autre signal, le masque. On appelle cet effet le masquage et le signal inaudible est le masqué. Il faut distinguer deux cas:

- Masquage simultané

Dans ce cas, le masque et le masqué sont présentés en même temps et sont quasi stationnaires. Si le masque a une largeur de bande discrète, le seuil auditif est élevé même pour des fréquences inférieures ou supérieures à celles du masque. La quantité de masquage dépend de la structure du masque et du masqué. Dans le cas où un signal semblable à un bruit masque un signal tonal, la quantité de masquage est presque indépendante de la fréquence. Si le niveau de pression sonore du masqué est d'environ 5 dB inférieure au niveau du masque, il devient inaudible. Dans le cas où un signal tonal masque un signal semblable à un bruit, la quantité de masquage dépend de la

fréquence du masque. La formule $\left(15,5 + \frac{z}{\text{Bark}}\right) \text{dB}$, où z est la bande critique du masque, peut en donner une estimation. En outre, pour des signaux de haut niveau, des effets non linéaires réduisent le seuil de masquage aux alentours du masque. On retrouve des effets similaires si un signal tonal masque un autre signal tonal. Les seuils de masquage de plusieurs signaux s'ajoutent de façon non linéaire. Le seuil de masquage qui en résulte est généralement supérieur au seuil de masquage de chaque signal pris individuellement.

– Masquage temporel

Dans ce cas, le masque et le masqué sont présentés à des moments différents. Peu après la fin du son masquant, le seuil de masquage est plus proche du masquage simultané de ce masque que du seuil absolu. Selon la durée du masque, le temps d'affaiblissement du seuil peut être compris entre 5 ms (masque: impulsion gaussienne d'une durée d'environ 0,05 ms) et plus de 150 ms (masque: bruit rose d'une durée de 1 s). Les signaux faibles émis juste avant des signaux plus puissants sont masqués. La durée de cet effet de prémasquage est d'environ 5 ms. Si le masqué est juste au-dessus du seuil, il n'est pas perçu avant le masque mais comme une modification du masque. Le prémasquage montre de fortes déviations d'un auditeur à un autre.

3.6 Intensité acoustique et masquage partiel

L'intensité acoustique perçue de signaux sonores dépend de leur fréquence, de leur durée, et du niveau de pression sonore. Du fait de l'auto-masquage, l'intensité acoustique d'un signal complexe est moindre que la somme de l'intensité acoustique de toutes ses composantes. Dans le contexte de la mesure de la qualité d'un son, l'intensité acoustique de la distorsion indésirable ajoutée au Signal de référence, l'intensité acoustique du bruit, est réduite par le masquage partiel causé par le Signal de référence.

3.7 Acuité

L'acuité, une des principales composantes de la sensation, est liée au timbre. Un son est perçu comme étant aigu s'il contient principalement des composantes de hautes fréquences. Par exemple, un son sinusoïdal ou un bruit de bande limitée de hautes fréquences, ou un bruit passe-haut de fréquence limite supérieure à environ 3 kHz est dit aigu. Les détails de la structure fréquentielle du signal sonore, n'a cependant pas une influence majeure sur l'acuité. C'est G. V. Bismarck [von Bismarck, 1974] qui a mené la recherche fondamentale sur l'acuité.

En ce qui concerne l'acuité, des recherches complémentaires ont été effectuées en 1984 par W. Aures [Aures, 1984]. Le résultat de ces recherches est une légère modification de la fonction de pondération par rapport à la fonction de pondération définie par Bismarck. En ce qui concerne l'évaluation de l'acuité, elle joue un rôle moins important dans les bandes critiques très basses et très hautes, et un rôle plus important dans les bandes critiques comprises entre 14 et 20 Bark. En outre, ces recherches ont montré que l'acuité des signaux sonores présentant une forte variation du niveau de pression sonore et un contenu important en fréquences élevées ne peut être fondée uniquement sur l'intensité acoustique, mais aussi sur une fonction de pondération, qui dépend de l'intensité acoustique globale.

3.8 Traitement cognitif

Il est évident que la qualité du son perçu est fortement influencée par les effets cognitifs. Une expérience simple permet de le démontrer.

Un Signal de référence comportant un bruit de fond clairement audible est traité par un équipement audio quelconque qui ne peut pas transmettre ce bruit de fond. Le bruit étant une distorsion indésirable, le Signal de référence serait moins bien noté que le signal traité lors d'un essai d'écoute. A l'opposé, c'est ce même signal traité qui serait moins bien noté si la partie la plus importante du Signal de référence était ce léger bruit de fond.

Donner une liste de tous les effets cognitifs possibles n'est pas du domaine de cet Appendice, mais on peut en donner quelques exemples:

1) Séparation des distorsions linéaires des distorsions non linéaires

Les distorsions linéaires sont moins gênantes que les distorsions non linéaires. La séparation des distorsions linéaires des distorsions non linéaires peut relativement facilement être mise en œuvre par un filtrage rétrograde adaptable du signal de sortie. La méthode définie dans cette Recommandation fait usage d'une séparation des distorsions linéaires des distorsions non linéaires.

2) Analyse du paysage auditif

L'analyse du paysage auditif [Bregman, 1990] est un processus cognitif qui permet aux auditeurs de séparer différents événements auditifs et de les regrouper en différents objets. On trouvera en [Beerends et Stemerding, 1994] une approche pragmatique utile pour quantifier un effet d'analyse du paysage auditif. Si une composante temps-fréquence n'est pas codée par un codec, le signal restant constitue toujours un paysage auditif cohérent, alors que l'introduction d'une nouvelle composante temps-fréquence sans relation avec le signal conduit à deux perceptions différentes. Du fait de ce partage en deux perceptions différentes, la distorsion sera plus gênante que ce qu'on aurait pu attendre sur la base de l'intensité acoustique de la nouvelle composante de distorsion introduite. Cela conduit à une asymétrie de perception entre la dégradation apportée par une distorsion causée par le non codage d'une composante temps-fréquence et la dégradation causée par l'introduction d'une nouvelle composante temps-fréquence.

3) Masquage informationnel

On peut modéliser le masquage informationnel en définissant une mesure de la complexité spectro-temporelle semblable à l'entropie. Cet effet dépend très probablement de la formation que les sujets ont reçue avant l'évaluation subjective. On trouvera une première tentative de modélisation de cet effet en [Beerends et autres, 1996], où est calculée une estimation de la complexité locale sur une fenêtre temporelle d'environ 100 ms. Si cette complexité locale est élevée, les distorsions dans cette fenêtre temporelle sont plus difficiles à entendre que lorsque la complexité locale est peu élevée. La formation peut réduire le seuil de masquage de plusieurs dizaines de dB [Leek et Watson, 1984].

4) Pondération spectro-temporelle

Certaines régions spectro-temporelles du signal sonore sont porteuses de plus d'informations que d'autres, et peuvent, de ce fait, être plus importantes. On a découvert que la pondération spectro-temporelle était importante pour des jugements de qualité de codecs de la parole. Dans le langage parlé, certaines composantes spectro-temporelles, par exemple les sons voyelles, sont de façon évidente porteuses de plus d'informations que d'autres [Beerends et Stemerding, mars 1994]. A l'inverse, en musique, toutes les composantes spectro-temporelles du signal, même les silences, peuvent véhiculer de l'information.

4 Les modèles intégrés

4.1 DIX

La méthode de mesure perceptuelle DIX (Disturbance Index – Indice de Perturbation) [Thiede et Kabot, 1996] est fondée sur un banc de filtres auditifs qui offre une haute résolution temporelle et permet ainsi (par rapport aux approches fondées sur FFT) une modélisation plus précise d'effets temporels comme le prémasquage et le postmasquage. La structure temporelle fine des enveloppes de chaque filtre auditif est préservée et peut être utilisée pour obtenir des informations complémentaires sur les signaux et les distorsions introduites.

Les fréquences centrales de chaque filtre sont également réparties sur une échelle perceptuelle des hauteurs sonores. La partie supérieure du filtre est légèrement arrondie pour assurer que le nombre de filtres choisis couvre toute la gamme de fréquences sans ondulations dans la réponse en fréquence. Afin de modéliser les seuils de masquage, la pente des filtres décroît de façon exponentielle sur l'échelle de Bark. La pente des filtres dépend du niveau des signaux d'entrée. Dans la première version de DIX, la gamme des fréquences audibles était couverte par 80 filtres; ce chiffre sera ultérieurement réduit à 40, ce qui signifie que la résolution de fréquences correspond à environ 0,6 Bark. L'algorithme du banc de filtres est plutôt rapide par rapport à d'autres bancs de filtres comportant des filtres individuels, mais toujours plus gourmand en temps que des transformations fondées sur des blocs comme FFT et des transformations par ondelettes.

DIX adapte de façon dynamique les niveaux et les spectres entre le Signal testé et le Signal de référence afin de séparer les distorsions linéaires des distorsions non linéaires. Le système évalue la structure des enveloppes temporelles en sortie de filtres afin de modéliser l'augmentation du masquage due aux masques modulés et semblables à des bruits par rapport aux sons purs.

En comparant les représentations internes du Signal testé et du Signal de référence, on calcule de nombreux paramètres de sortie, dont l'intensité acoustique partielle des distorsions non linéaires, des indicateurs de la quantité de distorsions linéaires et des mesures des effets temporels et bilatéraux. On peut néanmoins parvenir à une bonne estimation de la qualité du son de base en n'utilisant que deux des paramètres de sortie: l'intensité acoustique partielle des distorsions non linéaires et un des indicateurs de quantité de distorsions linéaires permettent d'obtenir une estimation de la qualité sonore de base du Signal testé.

4.2 NMR

La méthode de mesure NMR (Noise-to-Masked-Ratio – rapport bruit/masque) [Brandenburg, 1987] évalue la différence de niveaux entre le seuil de masquage et le signal de bruit. Pour analyser le contenu fréquentiel du signal, on utilise une DFT et une fenêtre de Hann d'environ 20 ms. Les coefficients de transformation sont associés aux bandes conformément à l'échelle de Bark. On estime le seuil de masquage pour chaque bande. La pente du seuil de masquage est obtenue par une approche du pire cas en prenant en compte le fait que les pentes sont plus accentuées pour les signaux faibles mais atteignent le seuil absolu pour des niveaux plus élevés. Le seuil absolu est adapté à la résolution du signal d'entrée (généralement 16 bit), mais pas aux exigences psychoacoustiques. Grâce à cela, NMR n'est pas affectée par les changements du niveau de reproduction. La résolution de l'échelle des hauteurs sonores est d'environ 1 Bark. La puissance de calcul nécessaire étant faible, il a été possible de mettre NMR en service comme système en temps réel dès les premières étapes de son développement.

Ce modèle, utilisé depuis 1987, a apporté la preuve de sa fiabilité de base.

Les valeurs de sortie les plus importantes fournies par NMR sont le taux d'indicateurs de masquage, le pourcentage de trames présentant des distorsions audibles, ainsi que le NMR total et moyen, qui sont autant de méthodes pour obtenir l'écart moyen entre l'énergie d'erreur et le seuil après masquage.

4.3 OASE

Le système de mesure OASE (Objective audio signal évaluation – Evaluation objective du signal audio) [Sporer, 1997] utilise un banc de filtres composé de 241 filtres pour analyser les signaux d'entrée. Les fréquences centrales sont également espacées sur l'échelle de Bark avec un écart de 0,1 Bark. Les filtres se recouvrent partiellement. Chaque filtre est adapté à la réponse en fréquence d'un point de la membrane basilaire. La dépendance des pentes au niveau est intégrée par une approche du pire cas, comme dans NMR. Les filtres des fréquences centrales basses nécessitent un calcul au taux d'échantillonnage complet, alors que les filtres des fréquences centrales hautes peuvent être calculés avec un taux d'échantillonnage réduit. Après les filtres, on calcule un modèle des effets temporels du système auditif humain comme dans ASD. Ensuite, il est possible de réduire le taux d'échantillonnage pour toutes les bandes de filtres. Cela conduit à une résolution temporelle du banc de filtres de 0,66 ms pour un taux d'échantillonnage de 48 kHz. Les sorties des filtres pour le signal référence et le signal testé sont comparées avec une fonction de probabilité de détection. Pour calculer la JNLD, cette fonction utilise comme entrée l'intensité acoustique des signaux d'entrée. La probabilité de détection totale est dérivée de la probabilité de détection de chaque bande. On effectue cette opération pour les deux canaux d'entrée, ainsi que pour le canal dit central. La probabilité de détection dans le canal central pour chaque bande est le pire cas de la probabilité de détection du canal de gauche et du canal de droite. Pour chaque trame de 0,66 ms la somme des pas au-dessus du seuil est également calculée.

Il existe plusieurs méthodes pour obtenir la moyenne temporelle de la probabilité de détection et les pas au-dessus du seuil:

- la moyenne temporelle de la probabilité de détection;
- la fréquence des trames de probabilité de détection supérieure à 0,5;
- la probabilité de détection maximum avec filtres passe-bas;
- la probabilité de détection maximum avec filtres passe-bas après oubli;
- le nombre moyen de pas au-dessus du seuil pour les trames de probabilité de détection supérieure à 0,5;
- le nombre moyen de pas au-dessus du seuil;
- le nombre maximum de pas au-dessus du seuil;
- le nombre moyen de pas au-dessus du seuil de 10% des moins bonnes trames.

4.4 PAQM (Perceptual Audio Quality Measure)

Le principe de base de PAQM [Beerends et Stemerding, 1992] est de soustraire les représentations internes (les représentations dans le cerveau du sujet) du signal de référence et du signal dégradé et de représenter cette différence sur un schéma cognitif de la qualité du son perçu de façon subjective. Le passage du domaine physique externe au domaine psychophysique interne se fait par l'intermédiaire de quatre opérations:

- une représentation temps-fréquence par l'intermédiaire d'une DFT avec une fenêtre de Hann d'une durée d'environ 40 ms;
- une déformation des fréquences avec l'échelle de Bark;
- un étalement temps-fréquence (convolution non linéaire);
- une déformation d'intensité (compression).

L'association de la dégradation et de la compression permet de modéliser le comportement de masquage du système auditif humain au niveau du seuil de masquage et au-dessus de celui-ci. La compression est optimisée avec les résultats subjectifs de la première évaluation du codec audio MPEG [ISO/IEC/JTC1/SC2/WG 11 MPEG/Audio test report, Document MPEG90/N0030, octobre 1990]. [ISO/IEC/JTC1/SC2/WG 11 MPEG/Audio test report, Document MPEG91/N0010, juin 1991]. La différence dans la représentation interne est exprimée en termes de gêne créée par le bruit. Dans les dernières versions de PAQM, soumises à l'UIT-R, deux effets cognitifs sont intégrés à la représentation de la dégradation créée par le bruit sur la qualité subjective, le flux perceptuel [Beerends et Stemerding, 1994] et le masquage informationnel [Beerends et autres, 1996].

Une version simplifiée de PAQM, la mesure perceptuelle de la qualité de la voix, PSQM [Beerends et Stemerding, 1994] fut développée avec un modèle cognitif présenté en [Beerends et Stemerding, 1994] mais étendue par une pondération des intervalles de silence. Lors du développement de PSQM, il apparut que lors du jugement de la qualité de la voix dans un contexte de téléphonie, le bruit qui apparaît lors des silences est moins important que le bruit qui apparaît dans les intervalles parlés. Lors d'un test de performance effectué par l'UIT-T, la proposition PSQM a montré la plus forte corrélation entre la qualité objective et la qualité subjective [UIT-T Commission d'études 12, «Review of validation tests for objective speech quality measures», contribution COH 12-74, mars 1996]. PSQM a été normalisé sous le nom de Recommandation UIT-T P.861 [«Objective quality measurement of telephone band (300-3400 Hz) speech codecs, août 1996»].

4.5 PERCEVAL

PERCEVAL (PERCEptual EVALuation – Evaluation Perceptuelle) [Pailland et autres, 1992] modélise les caractéristiques de transfert par l'oreille moyenne et par l'oreille interne pour constituer une représentation interne du signal. Le signal d'entrée est décomposé en une représentation temps-fréquence avec une DFT. Typiquement, une fenêtre de Hann d'environ 40 ms est appliquée aux données d'entrée, avec un recouvrement de 50% des fenêtres successives. Le spectre d'énergie est multiplié par une fonction dépendant de la fréquence qui modélise l'effet du canal auditif et de l'oreille moyenne. Les valeurs atténuées de l'énergie spectrale sont transformées de l'échelle des fréquences sur l'échelle de hauteurs sonores, qui est plus linéaire en ce qui concerne les propriétés physiques de l'oreille interne et les effets psychophysiques observés. Les composantes transformées de l'énergie sont alors convoluées avec une fonction d'étalement pour simuler la dispersion de l'énergie sur la membrane basilaire. Enfin, une énergie intrinsèque dépendant de la fréquence est ajoutée à chaque composante de la hauteur sonore pour prendre en compte le seuil d'audition absolu. La conversion de l'énergie en décibels a pour résultat la représentation du signal sur la membrane basilaire.

Lors de simulations d'expériences de masquage auditif, une représentation sur membrane basilaire est créée pour chaque stimulus, et la différence entre les représentations est l'information disponible pour effectuer le travail. Une des représentations est celle du masque seul, l'autre est celle de l'association du masque et du signal d'essai. La différence est la composante du signal qui n'est pas masquée. PERCEVAL calcule la probabilité de détection de cette différence. La probabilité de non-détection de la différence pour chaque détecteur le long de la membrane basilaire stimulée est estimée par une fonction de probabilité sigmoïde. En supposant que les détecteurs sont statistiquement indépendants, la probabilité globale de détection pour l'ensemble des détecteurs est calculée en prenant le complément du produit des probabilités individuelles de non-détection. Plusieurs expériences de masquage ont pu être simulées avec succès grâce à cette approche, et ce modèle a servi à évaluer la faisabilité de la modélisation individuelle d'auditeurs [Treurniet, 1996].

Outil d'estimation de la qualité du son, PERCEVAL calcule la différence entre les représentations du Signal de référence et du Signal testé. En appliquant des hypothèses raisonnables concernant les processus perceptuels et cognitifs de haut niveau, un certain nombre de variables pertinentes quant à la perception sont calculées et représentées par rapport à une mesure de la qualité objective du Signal testé. Cette représentation a été optimisée en minimisant la différence entre la distribution de la qualité objective et la distribution correspondante des taux moyens de qualité subjective pour l'ensemble des données disponibles.

4.6 POM

Le but de la mesure perceptuelle objective (POM) [Colomes et autres, 1995] est de quantifier la dégradation qui peut apparaître entre un Signal de référence et sa version dégradée. On y parvient en comparant la représentation basilaire interne des deux signaux, quelle que soit la cause de la dégradation. La représentation basilaire modélise les divers processus auxquels est soumis un signal sonore lorsqu'il est véhiculé dans l'oreille humaine. Ainsi, la première étape de POM est le calcul de la représentation interne d'un signal sonore. Les caractéristiques d'excitation (données en dB), sur la membrane basilaire, ont été choisies pour modéliser le taux de décharge des potentiels d'action dans les neurones le long de la membrane basilaire.

On appelle oreille artificielle ce processus de calcul des caractéristiques de l'excitation. Ensuite, lorsque l'on a obtenu les deux représentations internes des signaux à comparer, POM doit déterminer si la différence entre leurs représentations internes est audible ou non, et si oui, de quelle façon. C'est ce que l'on appelle le processus de détection.

POM utilise une DFT avec une fenêtre de Hann d'une durée d'environ 40 ms (avec un recouvrement de 50% entre deux fenêtres de Hann). Le nombre de canaux basilaire d'analyse est de 620. Les autres parties du modèle auditif sont presque identiques à celles utilisées soit par PAQM soit par PERCEVAL.

La fonction d'étalement est très précisément décrite par une approximation plus précise qui prend en compte la dépendance aux niveaux selon [Terhardt, 1972] et la forme arrondie selon [Schroeder et autres, 1979].

Ce modèle permet d'obtenir la probabilité de détection d'une distorsion entre les deux signaux comparés, ainsi que la distance dite basilaire qui représente l'écart de perception entre les deux excitations comparées.

4.7 L'approche Toolbox

Toolbox est une approche en trois étapes de la mesure de la distance perçue en qualité sonore d'un signal sonore d'essai par rapport à un signal sonore de référence, permettant ainsi d'obtenir une indication du niveau de qualité sonore subjective du signal d'essai. Cette méthode est fondée sur des modèles perceptuels bien connus qui sont utilisés pour décrire la représentation perceptuelle des différences entre les deux signaux sonores. En outre, elle intègre une procédure de pondération pour la qualité sonore perçue d'un signal d'essai stéréo, qui prend en compte les résultats du canal de gauche et du canal de droite. Une corrélation stricte sur une base échantillon par échantillon du signal de référence et du signal testé n'est pas nécessaire.

La principale fonctionnalité de Toolbox, étape 1, est fondée sur le calcul de l'intensité acoustique spécifique, selon [Zwicker et Feldtkeller, 1967], avec un FFT de 2 048 points, une fenêtre de Hann, qui correspond à une durée d'environ 40 ms. La fenêtre est déplacée par incréments de 10 ms. En outre, des effets de masquage temporel, postmasquage et prémasquage, selon Zwicker, sont appliqués. A partir de ces valeurs de base de la sensation, d'autres paramètres perceptuels, comme l'intensité intégrée, l'intensité partiellement masquée, l'acuité, selon [von Bismarck, 1974] et [Aures, 1984] et la quantité de prééchos sont calculés; il s'agit d'une étape de prétraitement dont les résultats sont utilisés pour les étapes suivantes.


La seconde étape de Toolbox intègre des procédures de pondération qui dépendent essentiellement de la quantité de différences perçues dans l'intensité et de la variation de l'intensité dans le temps.

La troisième étape de Toolbox intègre la génération d'un ensemble de valeurs de sortie qui sont des outils intermédiaires et sont fondées sur une analyse statistique des valeurs obtenues lors des étapes 1 et 2. Les résultats de cette analyse statistique comportent les valeurs moyenne, maximum et de r.m.s., ainsi que l'écart type des valeurs moyennes. Une somme pondérée de ces valeurs intermédiaires est utilisée pour la détermination finale de l'écart perceptuel entre le signal testé et le signal de référence. Si nécessaire, cette valeur de sortie unique peut être mise en concordance avec la note différentielle subjective, obtenue généralement lors d'essais d'écoute subjectifs, en faisant correspondre de façon séquentielle les données de sortie pour chaque incrément temporel avec des fonctions linéaires ou polynomiales d'ordre plus élevé.

Description du modèle³

1 Généralités

FIGURE 8
Diagramme générique du système de mesure



1387-08

Cette *méthode de mesure objective de la qualité du son perçu* est composée d'un *modèle auditif périphérique*, de plusieurs étapes intermédiaires (appelées ici «*prétraitement des caractéristiques d'excitation*»), du calcul (principalement) des *variables de sortie de modèle* («*MOV*») et d'une représentation d'un ensemble de variables de sortie de modèle par une valeur unique représentant la *qualité audio de base* du Signal testé. Elle comprend deux modèles auditifs, l'un fondé sur FFT et l'autre sur un banc de filtres. A l'exception du calcul du signal d'erreur (qui n'est utilisé qu'avec la partie du modèle fondée sur FFT), la structure générale des deux modèles est semblable.

³ Les inventeurs de la technologie décrite dans la présente Recommandation ont déposé des brevets conformément à l'Annexe 1 de la Résolution UIT-R 1-2. La technologie décrite dans la présente Recommandation est protégée par des brevets internationaux, et comme toutes les Recommandations de l'UIT, soumise aux droits d'auteur. L'accord préalable des propriétaires, sous la forme d'une licence, est obligatoire pour pouvoir exploiter cette technologie. Pour toute information complémentaire sur les droits de licence de cette technologie, consulter la base de données brevets de l'UIT-R, ou le secrétariat du BR.

Les entrées pour le calcul des MOV sont:

- Les caractéristiques d'excitation du Signal testé et du Signal de référence.
- Les caractéristiques d'excitation adaptés spectralement pour le Signal testé et le Signal de référence.
- Les caractéristiques spécifiques d'intensité pour le Signal testé et le Signal de référence.
- Les caractéristiques de modulation pour le Signal testé et le Signal de référence.
- Le signal d'erreur calculé comme étant la différence spectrale entre le Signal testé et le Signal de référence (uniquement pour le modèle fondé sur FFT).

Sauf indications contraires, dans le cas des signaux stéréo, tous les calculs sont effectués indépendamment et de la même façon pour le canal de gauche et le canal de droite.

Cette description définit deux ensembles, l'un appelé «*version de base*» et l'autre «*version avancée*».

Dans toutes les équations, l'indice «Ref.» représente toutes les caractéristiques calculées à partir du Signal de référence, et l'indice «Test» toutes les caractéristiques calculées à partir du Signal testé. L'indice «*k*» représente la variable de fréquence discrète (la bande de fréquences) et «*n*» la variable temporelle discrète (soit le compteur de trames, soit le compteur d'échantillons). Si les valeurs de ***k*** ou ***n*** ne sont pas explicitement définies, les calculs doivent être effectués pour toutes les valeurs possibles de ***k*** et ***n***. Toutes les autres abréviations sont expliquées à leur première occurrence.

Dans les noms des MOV, l'indice «*A*» représente toutes les variables calculées avec la partie du modèle auditif fondé sur le banc de filtres, et l'indice «*B*» toutes les variables calculées avec la partie du modèle auditif fondé sur FFT.

1.1 Version de base

La *version de base* n'intègre que les MOV calculées à partir du modèle FFT. On n'utilise pas la partie fondée sur le banc de filtres. La *version de base* utilise un total de 11 MOV pour la prédiction de la *qualité audio de base* perçue.

1.2 Version avancée


La *version avancée* intègre des MOV calculées à partir du modèle fondé sur le banc de filtres ainsi que des MOV calculées à partir du modèle FFT. Les caractéristiques d'excitation adaptées spectralement et les caractéristiques de modulation ne sont calculées qu'à partir de la partie fondée sur le banc de filtres du modèle. La *version avancée* utilise 5 MOV pour la prédiction de la *qualité audio de base* perçue.

2 Modèle auditif périphérique

2.1 Modèle auditif FFT

2.1.1 Aperçu général

FIGURE 9
Modèle auditif périphérique et prétraitement des caractéristiques d'excitation pour la partie du modèle FFT



L'entrée du modèle auditif FFT, Signal de référence et signal d'essai échantillonnés à 48 kHz et alignés temporellement, est découpée en trames d'environ 0,042 s avec un recouvrement de 50%. Chaque trame est transformée dans le domaine fréquentiel avec une fenêtre de Hann et une FFT à court terme, et ajusté au niveau de reproduction. Une fonction de pondération est appliquée aux coefficients du spectre, laquelle modélise la réponse en fréquence de l'oreille externe et de l'oreille moyenne. La transformation en une représentation dans le domaine des hauteurs sonores est obtenue en regroupant les coefficients pondérés du spectre en bandes critiques. Un décalage dépendant de la fréquence est ajouté pour simuler le bruit interne du système auditif. Une fonction d'étalement dépendante du niveau est utilisée pour modéliser les filtres auditifs de spectre dans le domaine fréquentiel. Ensuite, un étalement dans le domaine temporel rend compte des effets de prémasquage.

Les *caractéristiques d'excitation* obtenues sont utilisées pour calculer les *caractéristiques spécifiques d'intensité* et les *caractéristiques de masquage*. Les caractéristiques précédant l'étalement final dans le domaine temporel («*caractéristiques d'excitation non dégradée*») sont utilisées pour calculer les *caractéristiques de modulation*.

Pour modéliser le signal d'erreur, les caractéristiques des signaux de référence et d'essai de sortie de filtre de l'oreille externe et moyenne sont associées et représentées sur l'échelle des hauteurs sonores en les regroupant en bandes critiques.

Ces sorties sont utilisées avec les caractéristiques d'excitation pour calculer les valeurs des variables de sortie de modèle.

2.1.2 Traitement temporel

L'entrée du modèle auditif FFT, signal d'essai et Signal de référence, est découpée en trames de 2 048 échantillons avec un recouvrement de 1 024 échantillons:

$$t_n[k_t, n] = t[1024 \cdot n + k_t] \quad n = 0, 1, 2 \dots k_e = 0..2047 \quad (1)$$

où n est le numéro de la trame temporelle et k_e un compteur de temps dans une trame.

2.1.3 FFT

Le passage du domaine temporel au domaine fréquentiel se fait avec une fenêtre de Hann:

$$h_w[k] = \frac{1}{2} \sqrt{\frac{8}{3}} \left[1 - \cos\left(2\pi \frac{k}{N-1}\right) \right] \quad \left| \quad N = 2048 \quad (2) \right.$$

$$t_w[k_t, n] = h_w[k_t] \cdot t_n[k_t, n] \quad (3)$$

suivi par une transformation de Fourier à court terme:

$$F_f[k_f, n] = \frac{1}{2048} \sum_{k_t=0}^{2047} t_w[k_t, n] e^{-j \frac{2\pi}{2048} k_f k_t} \quad (4)$$

Le facteur d'échelle de la FFT est calculé à partir du niveau de pression sonore supposé L_P d'une onde sinusoïdale à pleine échelle par l'équation:

$$fac = \frac{10^{\frac{L_P}{20}}}{Norm} \quad (5)$$

$$F[k_f, n] = fac \cdot F_f[k_f, n] \quad (6)$$

où le facteur de normalisation *Norm* est calculé en prenant pour signal d'entrée une onde sinusoïdale de 1 019,5 Hz et 0 dB à pleine échelle et en calculant la valeur absolue maximum des coefficients de spectre sur 10 trames.

Si le niveau de pression sonore est inconnu, nous recommandons $L_P = 92 \text{ dB}_{SPL}$.

2.1.4 Oreille externe et oreille moyenne

La réponse en fréquence de l'oreille externe et de l'oreille moyenne est modélisée par une fonction de pondération dépendante de la fréquence:

$$W[k]/dB = -0,6 \cdot 3,64 \cdot \left(\frac{f[k]}{kHz}\right)^{-0,8} + 6,5 \cdot e^{-0,6 \cdot \left(\frac{f[k]}{kHz}\right)^{-3,3}} - 10^{-3} \cdot \left(\frac{f[k]}{kHz}\right)^{3,6} \quad (7)$$

où

$$f[k]/Hz = k \cdot 23.4375 \quad (8)$$

est la représentation de la fréquence sur la ligne k appliquée aux sorties FFT (équation 9).

$$F_e[k_f, n] = |F[k_f, n]| \cdot 10^{\frac{w[k_f]}{20}} \quad (9)$$

$F_e[k_f]$ sont les «sorties FFT pondérées de l'oreille externe».

2.1.5 Regroupement en bandes critiques

L'échelle auditive des hauteurs sonores est calculée à partir d'une approximation donnée par [Schroeder et autres, 1979].

$$z / Bark = 7 \cdot \operatorname{arsinh}\left(\frac{f / Hz}{650}\right) \quad (10)$$

Les unités de hauteur sonore sont appelées *Bark* (bien que cette échelle ne représente pas exactement l'échelle de Bark définie par [Zwicker et Feldtkeller, 1967]).

Les limites de fréquence des filtres sont dans une fourchette située entre 80 Hz et 18 000 Hz. La largeur et l'espacement des bandes de filtres correspondent à une résolution de $res=0,25$ Bark pour la version de base et $res=0,5$ Bark pour la version avancée.

Ce qui conduit à un nombre de bandes de fréquences $Z=109$ pour la version de base et $Z=55$ pour la version avancée.

TABLEAU 7

Bandes de fréquences du modèle auditif FFT dans la version de base

Groupe	Fréquence basse/Hz	Fréquence centrale/Hz	Fréquence haute/Hz	Largeur de fréquences/Hz
k	$f_l[k]$	$f_c[k]$	$f_u[k]$	$f_w[k]$
0	80	91,708	103,445	23,445
1	103,445	115,216	127,023	23,577
2	127,023	138,87	150,762	23,739
3	150,762	162,702	174,694	23,932
4	174,694	186,742	198,849	24,155
5	198,849	211,019	223,257	24,408
6	223,257	235,566	247,95	24,693
7	247,95	260,413	272,959	25,009
8	272,959	285,593	298,317	25,358

TABLEAU 7 (Suite)

Groupe	Fréquence basse/Hz	Fréquence centrale/Hz	Fréquence haute/Hz	Largeur de fréquences/Hz
k	$f_l [k]$	$f_c [k]$	$f_u [k]$	$f_w [k]$
9	298,317	311,136	324,055	25,738
10	324,055	337,077	350,207	26,151
11	350,207	363,448	376,805	26,598
12	376,805	390,282	403,884	27,079
13	403,884	417,614	431,478	27,594
14	431,478	445,479	459,622	28,145
15	459,622	473,912	488,353	28,731
16	488,353	502,95	517,707	29,354
17	517,707	532,629	547,721	30,014
18	547,721	562,988	578,434	30,713
19	578,434	594,065	609,885	31,451
20	609,885	625,899	642,114	32,229
21	642,114	658,533	675,161	33,048
22	675,161	692,006	709,071	33,909
23	709,071	726,362	743,884	34,814
24	743,884	761,644	779,647	35,763
25	779,647	797,898	816,404	36,757
26	816,404	835,17	854,203	37,799
27	854,203	873,508	893,091	38,888
28	893,091	912,959	933,119	40,028
29	933,119	953,576	974,336	41,218
30	974,336	995,408	1016,797	42,461
31	1016,797	1038,511	1060,555	43,758
32	1060,555	1082,938	1105,666	45,111
33	1105,666	1128,746	1152,187	46,521
34	1152,187	1175,995	1200,178	47,991
35	1200,178	1224,744	1249,7	49,522
36	1249,7	1275,055	1300,816	51,116
37	1300,816	1326,992	1353,592	52,776
38	1353,592	1380,623	1408,094	54,502
39	1408,094	1436,014	1464,392	56,298
40	1464,392	1493,237	1522,559	58,167
41	1522,559	1552,366	1582,668	60,109
42	1582,668	1613,474	1644,795	62,128
43	1644,795	1676,641	1709,021	64,226
44	1709,021	1741,946	1775,427	66,406
45	1775,427	1809,474	1844,098	68,671
46	1844,098	1879,31	1915,121	71,023
47	1915,121	1951,543	1988,587	73,466
48	1988,587	2026,266	2064,59	76,003
49	2064,59	2103,573	2143,227	78,637

TABLEAU 7 (Suite)

Groupe	Fréquence basse/Hz	Fréquence centrale/Hz	Fréquence haute/Hz	Largeur de fréquences/Hz
k	$f_l [k]$	$f_c [k]$	$f_u [k]$	$f_w [k]$
50	2143,227	2183,564	2224,597	81,371
51	2224,597	2266,34	2308,806	84,208
52	2308,806	2352,008	2395,959	87,154
53	2395,959	2440,675	2486,169	90,21
54	2486,169	2532,456	2579,551	93,382
55	2579,551	2627,468	2676,223	96,672
56	2676,223	2725,832	2776,309	100,086
57	2776,309	2827,672	2879,937	103,627
58	2879,937	2933,12	2987,238	107,302
59	2987,238	3042,309	3098,35	111,112
60	3098,35	3155,379	3213,415	115,065
61	3213,415	3272,475	3332,579	119,164
62	3332,579	3393,745	3455,993	123,415
63	3455,993	3519,344	3583,817	127,823
64	3583,817	3649,432	3716,212	132,395
65	3716,212	3784,176	3853,348	137,136
66	3853,348	3923,748	3995,399	142,051
67	3995,399	4068,324	4142,547	147,148
68	4142,547	4218,09	4294,979	152,432
69	4294,979	4373,237	4452,89	157,911
70	4452,89	4533,963	4616,482	163,592
71	4616,482	4700,473	4785,962	169,48
72	4785,962	4872,978	4961,548	175,585
73	4961,548	5051,7	5143,463	181,915
74	5143,463	5236,866	5331,939	188,476
75	5331,939	5428,712	5527,217	195,278
76	5527,217	5627,484	5729,545	202,329
77	5729,545	5833,434	5939,183	209,637
78	5939,183	6046,825	6156,396	217,214
79	6156,396	6267,931	6381,463	225,067
80	6381,463	6497,031	6614,671	233,208
81	6614,671	6734,42	6856,316	241,646
82	6856,316	6980,399	7106,708	250,392
83	7106,708	7235,284	7366,166	259,458
84	7366,166	7499,397	7635,02	268,854
85	7635,02	7773,077	7913,614	278,594
86	7913,614	8056,673	8202,302	288,688
87	8202,302	8350,547	8501,454	299,152
88	8501,454	8655,072	8811,45	309,996
89	8811,45	8970,639	9132,688	321,237
90	9132,688	9297,648	9465,574	332,887

TABLEAU 7 (Suite)

Groupe	Fréquence basse/Hz	Fréquence centrale/Hz	Fréquence haute/Hz	Largeur de fréquences/Hz
k	$f_1[k]$	$f_c[k]$	$f_u[k]$	$f_w[k]$
91	9465,574	9636,52	9810,536	344,962
92	9810,536	9987,683	10168,013	357,477
93	10168,013	10351,586	10538,46	370,447
94	10538,46	10728,695	10922,351	383,891
95	10922,351	11119,49	11320,175	397,824
96	11320,175	11524,47	11732,438	412,264
97	11732,438	11944,149	12159,67	427,231
98	12159,67	12379,066	12602,412	442,742
99	12602,412	12829,775	13061,229	458,817
100	13061,229	13296,85	13536,71	475,48
101	13536,71	13780,887	14029,458	492,748
102	14029,458	14282,503	14540,103	510,645
103	14540,103	14802,338	15069,295	529,192
104	15069,295	15341,057	15617,71	548,415
105	15617,71	15899,345	16186,049	568,339
106	16186,049	16477,914	16775,035	588,986
107	16775,035	17077,504	17385,42	610,385
108	17385,42	17690,045	18000	614,58

TABLEAU 8

Bandes de fréquences du modèle auditif FFT dans la version avancée

Groupe	Fréquence basse/Hz	Fréquence centrale/Hz	Fréquence haute/Hz	Largeur de fréquence/Hz
k	$f_1[k]$	$f_c[k]$	$f_u[k]$	$f_w[k]$
0	80	103,445	127,023	47,023
1	127,023	150,762	174,694	47,671
2	174,694	198,849	223,257	48,563
3	223,257	247,95	272,959	49,702
4	272,959	298,317	324,055	51,096
5	324,055	350,207	376,805	52,75
6	376,805	403,884	431,478	54,673
7	431,478	459,622	488,353	56,875
8	488,353	517,707	547,721	59,368
9	547,721	578,434	609,885	62,164
10	609,885	642,114	675,161	65,277
11	675,161	709,071	743,884	68,723
12	743,884	779,647	816,404	72,52
13	816,404	854,203	893,091	76,687
14	893,091	933,119	974,336	81,245

TABLEAU 8 (Suite)

Groupe	Fréquence basse/Hz	Fréquence centrale/Hz	Fréquence haute/Hz	Largeur de fréquence/Hz
k	$f_l[k]$	$f_c[k]$	$f_u[k]$	$f_w[k]$
15	974,336	1016,797	1060,555	86,219
16	1060,555	1105,666	1152,187	91,632
17	1152,187	1200,178	1249,7	97,513
18	1249,7	1300,816	1353,592	103,892
19	1353,592	1408,094	1464,392	110,801
20	1464,392	1522,559	1582,668	118,275
21	1582,668	1644,795	1709,021	126,354
22	1709,021	1775,427	1844,098	135,077
23	1844,098	1915,121	1988,587	144,489
24	1988,587	2064,59	2143,227	154,64
25	2143,227	2224,597	2308,806	165,579
26	2308,806	2395,959	2486,169	177,364
27	2486,169	2579,551	2676,223	190,054
28	2676,223	2776,309	2879,937	203,713
29	2879,937	2987,238	3098,35	218,414
30	3098,35	3213,415	3332,579	234,229
31	3332,579	3455,993	3583,817	251,238
32	3583,817	3716,212	3853,348	269,531
33	3853,348	3995,399	4142,547	289,199
34	4142,547	4294,979	4452,89	310,343
35	4452,89	4616,482	4785,962	333,072
36	4785,962	4961,548	5143,463	357,5
37	5143,463	5331,939	5527,217	383,754
38	5527,217	5729,545	5939,183	411,966
39	5939,183	6156,396	6381,463	442,281
40	6381,463	6614,671	6856,316	474,853
41	6856,316	7106,708	7366,166	509,85
42	7366,166	7635,02	7913,614	547,448
43	7913,614	8202,302	8501,454	587,84
44	8501,454	8811,45	9132,688	631,233
45	9132,688	9465,574	9810,536	677,849
46	9810,536	10168,013	10538,46	727,924
47	10538,46	10922,351	11320,175	781,715
48	11320,175	11732,438	12159,67	839,495
49	12159,67	12602,412	13061,229	901,56
50	13061,229	13536,71	14029,458	968,229
51	14029,458	14540,103	15069,295	1039,837
52	15069,295	15617,71	16186,049	1116,754
53	16186,049	16775,035	17385,42	1199,371
54	17385,42	17690,045	18000	614,58

La représentation de la fréquence par rapport à la hauteur sonore est obtenue par l'algorithme décrit dans l'alinéa suivant, où $Fsp[k_f]$ est la représentation de l'énergie des «Sorties FFT pondérées de l'oreille externe»:

$$Fsp[k_f, n] = |F_e[k_f, n]|^2 \quad (11)$$

ou la représentation de l'énergie du signal d'erreur:

$$Fsp[k_f, n] = |F_{noise}[k_f, n]|^2 \quad (12)$$

respectivement. Voir le calcul du signal d'erreur dans le § 3.4.

Les résultats de cette étape du traitement sont les énergies des groupes de fréquences, $P_e[k, n]$.

2.1.5.1 Pseudo-code

```

/* inputs */
Fsp[ ]           Energies d'entrée
/* outputs */
Pe[ ]           : énergies dans le domaine des hauteurs sonores
/* intermediate values */
i               : indice des groupes de fréquences
k               : \ indice de la ligne fft
Z               Nombre de groupes de fréquences:
                  109 pour la version de base
                  55 pour la version avancée
fl[]           : fréquence basse du groupe de fréquences
fu[]           : fréquence haute du groupe de fréquences
Fres           : constante pour résolution en fréquences

```

```

Fres = 48000/2048;
for(i=0; i<Z; i++)
{
  Pe[i]=0;
  for(k=0;k<1024;k++)
  {
    /* line inside frequency group */
    if( (( k-0.5)*Fres >= fl[i]) && ((k+0.5)*Fres <= fu[i]))
    {
      Pe[i] += Fsp[k];
    }
    /* frequency group inside*/
    else if( (( k-0.5)*Fres < fl[i]) && ((k+0.5)*Fres > fu[i]))

```

```

{
  Pe[i] += Fsp[k]*(fl[i]-fu[i])/Fres;
}
/* left border */
else if( ((k-0.5)*Fres < fl[i]) && ((k+0.5)*Fres > fl[i]))
{
  Pe[i] += Fsp[k]*( (k+0.5)*Fres - fl[i])/Fres;
}
/* right border
else if( ((k-0.5)*Fres < fu[i]) && ((k+0.5)*Fres > fu[i]);
{
  Pe[i] += Fsp[k]*(fu[i]- (k-0.5)*Fres)/Fres;
}
/* line outside frequency group */
else
{
  Pe[i] += 0;
}
}

/* limit result */
Pe[i]=max(Pe[i],0.000000000001);
}

```

2.1.6 Ajout de bruit interne

Un écart dépendant de la fréquence P_{Thres} est ajouté aux énergies dans chaque groupe de fréquences:

$$P_{Thres}[k] = 10^{0,4 \times 0,364 \left(\frac{f_c[k]}{\text{kHz}} \right)^{-0,8}} \quad (13)$$

$$P_p[k, n] = P_e[k, n] + P_{Thres}[k] \quad (14)$$

Les résultats de cette étape du traitement, $P_p[k, n]$ sont les «*caractéristiques des hauteurs sonores*».

2.1.7 Etalement

Les *caractéristiques de hauteur sonore* $P_p[k, n]$ sont dégradés en fréquence par une fonction d'étalement dépendante du niveau. La fonction d'étalement est une fonction exponentielle double. La pente inférieure est toujours 27 dB/Bark et la pente supérieure dépend de la fréquence et de l'énergie.

Les pentes sont calculées de la façon suivante:

$$\frac{S_u[k, L[k, n]]}{dB / Bark} = -24 - \frac{230Hz}{f_c[k]} + 0,2 \cdot L[k, n] / dB \quad (15)$$

$$S_l[k, L[k, n]] = 27 \frac{dB}{Bark} \quad (16)$$

avec

$$L[k, n] = 10 \cdot \log_{10}(P_p[k, n])$$

L'étalement est effectué indépendamment pour chaque groupe de fréquences k :

$$E_2[k, n] = \frac{1}{Norm_{SP}[k]} \left(\sum_{j=0}^Z E_{line}[j, k, n] \right)^{0,4} \quad (17)$$

où E_{line} est donné par:

$$E_{line}[j, k, n] = \begin{cases} \frac{\frac{L[j, n]}{10} \frac{-res \cdot (j-k) \cdot s_l[j, L[j, n]]}{10}}{\sum_{\mu=0}^{j-1} \frac{-res \cdot (j-\mu) \cdot s_l[j, L[j, n]]}{10} + \sum_{\mu=j}^Z \frac{res \cdot (\mu-j) \cdot s_u[j, L[j, n]]}{10}} & \text{si } k < j \\ \frac{\frac{L[j, n]}{10} \frac{res \cdot (k-j) \cdot s_u[j, L[j, n]]}{10}}{\sum_{\mu=0}^{j-1} \frac{-res \cdot (j-\mu) \cdot s_l[j, L[j, n]]}{10} + \sum_{\mu=j}^Z \frac{res \cdot (\mu-j) \cdot s_u[j, L[j, n]]}{10}} & \text{si } k \geq j \end{cases} \quad (18)$$

$Norm_{SP}[k]$ est calculé de la façon suivante:

$$Norm_{SP}[k] = \left(\sum_{j=0}^Z \tilde{E}_{line}[j, k] \right)^{0,4} \quad (19)$$

où:

$$\tilde{E}_{line}[j, k] = \begin{cases} \frac{\frac{-res \cdot (j-k) \cdot s_l[j, 0]}{10}}{\sum_{\mu=0}^{j-1} \frac{-res \cdot (j-\mu) \cdot s_l[j, 0]}{10} + \sum_{\mu=j}^Z \frac{res \cdot (\mu-j) \cdot s_u[j, 0]}{10}} & \text{si } k < j \\ \frac{\frac{res \cdot (k-j) \cdot s_u[j, 0]}{10}}{\sum_{\mu=0}^{j-1} \frac{-res \cdot (j-\mu) \cdot s_l[j, 0]}{10} + \sum_{\mu=j}^Z \frac{res \cdot (\mu-j) \cdot s_u[j, 0]}{10}} & \text{si } k \geq j \end{cases} \quad (20)$$

et res est la résolution de l'échelle des hauteurs sonores en Bark (0,25 pour la version de base et 0,5 pour la version avancée).

Les caractéristiques obtenues à ce stade du traitement, $\mathbf{E}_2[\mathbf{k}, \mathbf{n}]$, sont utilisées ultérieurement pour le calcul des caractéristiques de modulation et appelées «*caractéristiques d'excitation non dégradés*».

2.1.8 Étalement dans le domaine temporel

Afin de modéliser le postmasquage, les énergies de chaque groupe de fréquences sont dégradées temporellement par des filtres passe-bas de premier ordre. Les constantes temporelles dépendent de la fréquence centrale de chaque groupe (voir l'équation (10) et le Tableau 7) et sont calculées de la façon suivante:

$$\tau = \tau_{\min} + \frac{100\text{Hz}}{f_c[k]} \cdot (\tau_{100} - \tau_{\min}) \quad \left| \begin{array}{l} \tau_{100} = 0,030 \text{ s} \\ \tau_{\min} = 0,008 \text{ s} \end{array} \right. \quad (21)$$

Les filtres passe-bas de premier ordre sont calculés de la façon suivante:

$$E_f[k, n] = a \cdot E_f[k, n-1] + (1-a) \cdot E_2[k, n] \quad (22)$$

$$E[k, n] = \max(E_f(k, n), E_2(k, n)) \quad (23)$$

où a est calculé à partir des constantes temporelles ci-dessus par:

$$a = e^{-\frac{4}{187,5} \cdot \frac{1}{\tau}} \quad (24)$$

n est le numéro de trame, k est l'indice du groupe et $E_f[k, 0] = 0$

Les caractéristiques obtenues à ce stade du traitement, $\mathbf{E}[\mathbf{k}, \mathbf{n}]$, sont dénommées «*caractéristiques d'excitation*».

2.1.9 Seuil de masquage

Le masquage est l'effet par lequel un signal faible mais distinctement audible devient inaudible lorsqu'apparaît un signal comparativement plus puissant. Le seuil est calculé en pondérant les caractéristiques d'excitation avec la fonction de pondération $m[k]$.

$$m[k] = \begin{cases} 3,0 & k \cdot \text{res} \leq 12 \\ 0,25 \cdot k \cdot \text{res} & k \cdot \text{res} > 12 \end{cases} \quad (25)$$


$$M[k, n] = \frac{E[k, n]}{10^{\frac{m[k]}{10}}} \quad (26)$$

A ce stade du traitement, les caractéristiques $\mathbf{M}[\mathbf{k}, \mathbf{n}]$, sont dénommées «*caractéristiques de masques*».

2.2 Modèle auditif fondé sur un banc de filtres

2.2.1 Aperçu général

FIGURE 10
Modèle auditif périphérique et prétraitement des caractéristiques d'excitation pour la partie du modèle fondé sur le banc de filtres



1387-10

A l'entrée du modèle auditif fondé sur un banc de filtres, le Signal testé et le Signal de référence sont ajustés en fonction du niveau de reproduction supposé et envoyés à travers un filtre passe-haut afin de supprimer les composantes DC et subsoniques des signaux. Les signaux sont ensuite décomposés en signaux de bande passante par des filtres à phase linéaires également distribués sur une échelle perceptuelle des hauteurs sonores. Une pondération dépendante de la fréquence est appliquée aux signaux de bande passante afin de modéliser les caractéristiques spectrales de l'oreille

externe et de l'oreille moyenne. La résolution spectrale dépendante du niveau des filtres auditifs est modélisée par une convolution en domaine fréquentiel des sorties avec une fonction d'étalement dépendante du niveau.

Les enveloppes des signaux sont calculées selon la transformation de Hilbert des signaux passe-bande («rectification») et une convolution dans le domaine temporel avec une fonction de fenêtrage est appliquée afin de modéliser le prémasquage. Ensuite, un écart dépendant de la fréquence est ajouté pour prendre en compte le bruit interne du système auditif et modéliser le seuil au repos. Enfin, une deuxième convolution dans le domaine temporel est effectuée avec une fonction d'étalement exponentielle qui modélise le prémasquage.


Les *caractéristiques d'excitation* obtenues sont utilisées pour calculer les *caractéristiques spécifiques d'intensité*, et les caractéristiques avant l'étalement final dans le domaine temporel («*caractéristiques d'excitation non dégradées*») sont utilisées pour calculer les *caractéristiques de modulation*. Celles-ci, avec les caractéristiques d'excitation, sont la base sur laquelle les valeurs du modèle sont calculées. Afin de séparer l'influence de la réponse en fréquence du système testé des autres distorsions, les caractéristiques d'excitation du signal d'essai et du Signal de référence sont également adaptées spectralement l'une à l'autre («adaptation»). Les caractéristiques de modulation et les caractéristiques spécifiques d'intensité sont calculées à partir des caractéristiques d'excitation adaptées et non adaptées.

2.2.2 Sous-échantillonnage

A la sortie du banc de filtres, les signaux sont sous-échantillonnés d'un facteur 32 et après le premier étalement dans le domaine temporel, les signaux sont sous-échantillonnés d'un facteur 6 (voir la Figure 11).

FIGURE 11

Sous-échantillonnage dans le modèle auditif fondé sur un banc de filtres



2.2.3 Réglage au niveau de reproduction

Le facteur de graduation pour l'entrée est calculé à partir du niveau de reproduction supposé d'un signal d'entrée pleine échelle par la formule:

$$fac = \frac{10^{L_{\max}/20}}{32767} \quad (27)$$

Si le niveau de reproduction exact n'est pas connu, il est conseillé de régler L_{\max} sur 92 dB_{SPL}.

2.2.4 Filtre de réjection DC

Le banc de filtres étant sensible aux infrasons présents dans les signaux d'entrée, on applique aux signaux d'entrée un filtre de rejection DC. On utilise un filtre passe-haut de Butterworth de quatrième ordre d'une fréquence limite de 20 Hz. Ce filtre est une cascade de deux filtres IIR de second ordre:

$$y_n = x_n - 2x_{n-1} + x_{n-2} + b_1 y_{n-1} + b_2 y_{n-2} \quad (28)$$

où les coefficients du premier bloc sont:

$$b_{1,2} = 1,99517, -0,995174$$

et les coefficients du second bloc sont:

$$b_{1,2} = 1,99799, -0,997998.$$

2.2.5 Banc de filtres

Le banc de filtres est composé de 40 paires de filtres pour chaque canal du signal d'essai et du Signal de référence. Les filtres sont espacés régulièrement et ont une largeur de bande absolue constante quand ils sont liés à une échelle auditive des hauteurs sonores. Chaque paire de filtres est composée de deux filtres à réponse en fréquence égale mais avec une différence de 90° en réponse en phase. Ainsi, la sortie du second filtre représente la transformation de Hilbert de la sortie du premier filtre (ou la partie imaginaire, si le premier filtre est supposé représenter la partie réelle d'un signal complexe). Les enveloppes de leurs réponses impulsionnelles ont une forme en \cos^2 . Les filtres sont définis dans le Tableau 9 et par l'équation (29) (où k est l'indice du filtre, n l'indice de l'échantillon temporel et T la durée entre deux échantillons: $T=1/48000$). Ils peuvent être réalisés comme des filtres FIR en prenant pour coefficients les valeurs $h_{re}(k, n)$ et $h_{im}(k, n)$. Si les signaux d'entrée sont temporellement limités, les sorties de filtres peuvent aussi être calculées par des algorithmes récurrents très rapides.

$$\begin{aligned} h_{re}(k, n) &= \frac{4}{N[n]} \cdot \sin^2\left(\pi \cdot \frac{n}{N[k]}\right) \cdot \cos\left(2\pi \cdot f_c[k] \cdot \left(n - \frac{N[k]}{2}\right) \cdot T\right) \\ h_{im}(k, n) &= \frac{4}{N[n]} \cdot \sin^2\left(\pi \cdot \frac{n}{N[k]}\right) \cdot \sin\left(2\pi \cdot f_c[k] \cdot \left(n - \frac{N[k]}{2}\right) \cdot T\right) \\ h_{re}(k, n) &= h_{im}(k, n) = 0 \end{aligned} \quad \left| \begin{array}{l} 0 \leq n < N[k] \\ n < 0 \\ n \geq N[k] \end{array} \right. \quad (29)$$

Les fréquences centrales sont situées entre 50 Hz et 18 000 Hz. L'échelle auditive des hauteurs sonores est calculée à partir de l'approximation donnée par [Schroeder et autres, 1979]:

$$z / \text{Bark} = 7 \cdot \text{arsinh}\left(\frac{f / \text{Hz}}{650}\right) \quad (30)$$

Les unités de hauteur sonore sont dénommées *Bark* (bien que cette échelle ne représente pas exactement l'échelle de Bark définie par [Zwicker et Feldtkeller, 1967]).

TABLEAU 9

Fréquence centrale, durée de la réponse en impulsion et retard complémentaire pour chaque filtre

Indice du filtre	Fréquence centrale/Hz	Durée de la réponse en impulsion/échantillons	Retard complémentaire/échantillons
k	$f_c [k]$	$N[k]$	$D[k]$
0	50,00	1456	1
1	116,19	1438	10
2	183,57	1406	26
3	252,82	1362	48
4	324,64	1308	75
5	399,79	1244	107
6	479,01	1176	141
7	563,11	1104	177
8	652,97	1030	214
9	749,48	956	251
10	853,65	884	287
11	966,52	814	322
12	1089,25	748	355
13	1223,10	686	386
14	1369,43	626	416
15	1529,73	570	444
16	1705,64	520	469
17	1898,95	472	493
18	2111,64	430	514
19	2345,88	390	534
20	2604,05	354	552
21	2888,79	320	569
22	3203,01	290	584
23	3549,90	262	598
24	3933,02	238	610
25	4356,27	214	622
26	4823,97	194	632
27	5340,88	176	641
28	5912,30	158	650
29	6544,03	144	657
30	7242,54	130	664
31	8014,95	118	670

TABLEAU 9 (Suite)

Indice du filtre	Fréquence centrale/Hz	Durée de la réponse en impulsion/échantillons	Retard complémentaire/échantillons
k	$f_c[k]$	$N[k]$	$D[k]$
32	8869,13	106	676
33	9813,82	96	681
34	10858,63	86	686
35	12014,24	78	690
36	13292,44	70	694
37	14706,26	64	697
38	16270,13	58	700
39	18000,02	52	703

Afin d'avoir les mêmes retards pour tous les filtres, l'entrée de chaque filtre est retardée de D échantillons, où D est la moitié de la différence entre la durée de sa réponse en impulsion et la durée de la réponse en impulsion du filtre de réponse la plus longue⁴:

$$D[k] = 1 + \frac{1}{2}(N[0] - N[k]). \quad (31)$$

Les sorties de filtres sont sous-échantillonnées selon un facteur 32, ce qui signifie que les valeurs de sortie sont calculées tous les 32 échantillons d'entrée pour tous les filtres⁵

2.2.6 Filtrage par l'oreille externe et par l'oreille moyenne

La réponse en fréquence de l'oreille externe et de l'oreille moyenne est modélisée par une fonction de pondération dépendante de la fréquence appliquée aux sorties de filtres (l'équation (32)).

$$W[k]/dB = -0,6 \cdot 3,64 \cdot \left(\frac{f_c[k]}{kHz}\right)^{-0,8} + 6,5 \cdot e^{-0,6 \left(\frac{f_c[k]}{kHz} - 3,3\right)^2} - 10^{-3} \cdot \left(\frac{f_c[k]}{kHz}\right)^{3,6} \quad (32)$$

2.2.6.1 Pseudo-code

/* inputs */

out_re,out_im : sorties du banc de filtres (parties réelle et imaginaire)

W : fonction de pondération (voir (32))

/* outputs */

out_re,out_im : sorties du banc de filtres

/* intermediate values */

k : indice du filtre

Wt : facteur de pondération

⁴ Le retard supplémentaire d'un échantillon n'est pas nécessaire pour une réalisation. Il convient de noter que la réalisation de référence utilisée pour les essais de conformité inclut ce retard supplémentaire.

⁵ En fait, les enveloppes des filtres dans les bandes de hautes fréquences ne sont pas nécessairement conformes au théorème d'échantillonnage. Même si l'aliasing n'apparaît que dans certaines conditions très particulières (à savoir composantes de hautes fréquences modulées avec des fréquences supérieures à 1,5 kHz) et si les problèmes liés à ces effets ne sont jamais apparus dans les bases de données connues, il faut préciser qu'il peut y avoir des problèmes d'aliasing en particulier avec des signaux d'essai synthétisés.

```

/* outer and middle ear filtering */
for(k=0..39)
{
    Wt = pow(10,W[k]/20)
    out_re[k] *= Wt;
    out_im[k] *= Wt;
}

```

2.2.7 Étalement dans le domaine fréquentiel

Les valeurs de sortie du banc de filtres sont dégradées en fréquence par une fonction d'étalement dépendante du niveau. Cette fonction d'étalement est une fonction exponentielle double. La pente inférieure est toujours 31 dB/Bark et la pente supérieure varie entre -24 et -4 dB/Bark.

La pente supérieure, $s[k]$, est calculée par la formule:

$$\frac{s[k]}{dB / Bark} = \min\left(-4, -24 - \frac{230Hz}{f_c[k]} + 0.2 \cdot L[k] / dB\right) \quad (33)$$

Le niveau $L[k]$ est calculé indépendamment pour chaque canal de filtre en prenant le carré de la valeur absolue de la sortie du filtre et en le transformant sur l'échelle dB. Les fréquences centrales, $f_c[k]$ proviennent du Tableau 9. Les représentations linéaires des pentes sont temporellement amorties par un filtre passe-bas de premier ordre ayant une constante temporelle de 100 ms.

L'étalement est effectué indépendamment pour les filtres représentant la partie réelle des signaux et les filtres représentant les parties imaginaires des signaux (équation (29)). L'étalement de fréquence est d'abord effectué pour la pente supérieure (dépendante du niveau) puis pour la pente inférieure avec un algorithme de filtre IIR de premier ordre.

2.2.7.1 Pseudo-code

```

/* inputs */
out_re,out_im      : sorties du banc de filtres (parties réelle et imaginaire)
z[ ]               : bandes critiques pour les fréquences centrales des bandes de
                    filtres en Bark (conformément au Tableau 9 et à l'équation (30))

/* outputs */
A_re,A_im          : caractéristiques de sorties

/* intermediate values */
j,k                : indice du filtre
a,b                : coefficients d'amortissement temporel
dist               : constante de calcul des parasites
L[ ]               : niveau à chaque sortie de filtre
s[ ]               : pente locale d'étalement vers le haut
d1,d2              : tampons

/* static */
                    (les valeurs de la trame précédente sont conservées; les valeurs
                    sont initialisées avec des zéros au début de la mesure)

cl, cu[ ]          : fraction étalée du signal

```

```

/* level dependent upward spreading */
dist    = pow(0.1,(z[39]-z[0])/(39*20));
/* (z[39]-z[0])/39 is the distance in Bark between two adjacent filter bands */
a       = exp(-32/(48000*0.1));
b       = 1 - a;
for(k=0..39)
{
    A_re[k] = out_re[k];
    A_im[k] = out_im[k];
}
for(k=0..39)
{
    /* calculate level dependent slope */
    L[k] = 10*log10(out_re[k]* out_re[k] + out_im[k]* out_im[k]);
    s[k] = max(4,(24 + 230/fcentre[k] - 0.2*L[k]));
    /* calculate spreaded fraction and smooth it over time*/
    cu[k] = a*pow(dist,s[k])+b*cu[k];
    /* spreading of band k */
    d1    = out_re[k]
    d2    = out_im[k]
    for(j=k+1..39)
    {
        d1 *= cu[k];
        d2 *= cu[k];
        A_re[j] += d1;
        A_im[j] += d2;
    }
}
/* downward spreading */
c1      = pow(dist,31);
d1      = 0;
d2      = 0;
for(k=0..39)
{
    /* spreading of band k */
    d1    = d1 * c1 + A_re[k];
    d2    = d2 * c1 + A_im[k];
    A_re[k] = d1;
    A_im[k] = d2;
}

```

2.2.8 Rectification

On calcule les énergies en sortie de filtre en ajoutant le carré des valeurs du filtre représentant la partie réelle du signal à celui représentant la partie imaginaire du signal.

$$E_0[k, n] = A_{re}[k, n]^2 + A_{im}[k, n]^2 \quad (34)$$

Toutes les opérations suivantes sont effectuées sur ces énergies.

2.2.9 Dégradation dans le domaine temporel (1) – Prémasquage

Pour modéliser le prémasquage, les énergies en sortie de filtres sont temporellement dégradées par un filtre FIR de réponse impulsionnelle en \cos^2 avec 12 dérivations (ce qui correspond à une réponse de filtre de 384 échantillons au taux d'échantillonnage d'entrée du banc de filtres). Après dégradation temporelle, les sorties sont sous-échantillonnées selon un facteur 6. Les valeurs qui en résultent sont multipliées par un facteur d'étalonnage $ca1_1 = 0,9761$ afin d'obtenir les niveaux de sortie appropriés pour le niveau de reproduction donné.

$$E_1[k, n] = \frac{0,9761}{6} \cdot \sum_{i=0}^{11} E_0[k, 6n - i] \cdot \cos^2\left(\pi \cdot \frac{(i-5)}{12}\right) \quad (35)$$

2.2.10 Ajout de bruit interne

Après la première dégradation dans le domaine temporel, un écart dépendant de la fréquence E_{Thres} est ajouté aux énergies dans chaque canal de filtre.

$$E_{Thres}[k] = 10^{0,4 \times 0,364 \left(\frac{f_c[k]}{kHz}\right)^{-0,8}} \quad (36)$$

$$E_2[k, n] = E_1[k, n] + E_{Thres}[k, n] \quad (37)$$

A cette étape du traitement, les caractéristiques $E_2[k, n]$ sont utilisées ultérieurement pour le calcul des caractéristiques de modulation et sont dénommées «*caractéristiques d'excitation non dégradées*».

2.2.11 Dégradation dans le domaine temporel (2) – Postmasquage

Pour modéliser le postmasquage, les énergies dans chaque canal de filtre sont dégradées temporellement par des filtres passe-bas de premier ordre. Les constantes temporelles dépendent de la fréquence centrale de chaque filtre (donnée dans le Tableau 6) et sont obtenues par l'équation:

$$\tau = \tau_0 + \frac{100Hz}{f_c[k]} \cdot (\tau_{100} - \tau_{min}) \quad \left| \begin{array}{l} \tau_{100} = 0,020 \text{ s} \\ \tau_{min} = 0,004 \text{ s} \end{array} \right. \quad (38)$$

Les filtres passe-bas de premier ordre sont calculés selon l'équation:

$$E[k, n] = a \cdot E[k, n-1] + (1-a) \cdot E_2[k, n] \quad (39)$$

où a est calculé à partir des constantes temporelles ci-dessus par:

$$a = e^{-\frac{192}{48000 \cdot \tau}} \quad (40)$$

A ce stade du traitement, les caractéristiques $E[k, n]$ sont appelées «*caractéristiques d'excitation*».

3 Prétraitement des caractéristiques d'excitation

La plupart des calculs décrits dans ce paragraphe sont utilisés aussi bien avec le modèle auditif fondé sur le banc de filtres qu'avec le modèle FFT. Le facteur de sous-échantillonnage et le nombre de bandes de fréquences étant différents entre les deux modèles auditifs, les constantes qui dépendent de ce facteur sont décrites par les variables dépendantes du modèle auditif *StepSize* et *Z*. Pour le modèle auditif FFT, la valeur de *StepSize* est **1024** et celle de *Z* est soit **55** (*version avancée*), soit **109** (*version de base*). Pour le modèle auditif fondé sur le banc de filtres la valeur de *StepSize* est **192** et celle de *Z* est **40**.

3.1 Adaptation des niveaux et des caractéristiques

Pour compenser les différences de niveau et les distorsions linéaires entre le signal d'essai et le Signal de référence, on adapte les uns aux autres les niveaux moyens du Signal testé et du Signal de référence.

Les énergies dans chaque canal de filtre sont d'abord amorties par des filtres passe-bas de premier ordre. Les constantes temporelles dépendent des fréquences centrales des filtres et sont choisies de la façon suivante:

$$\tau = \tau_{\min} + \frac{100\text{Hz}}{f_c [k]} \cdot (\tau_{100} - \tau_{\min}) \quad \left| \begin{array}{l} \tau_{100} = 0,050 \text{ s} \\ \tau_{\min} = 0,008 \text{ s} \end{array} \right. \quad (41)$$

Les filtres passe-bas de premier ordre sont calculés de la façon suivante:

$$P_{Ref}[k, n] = a \cdot P_{Ref}[k, n-1] + (1-a) \cdot E_{Ref}[k, n] \quad (42)$$

$$P_{Test}[k, n] = a \cdot P_{Test}[k, n-1] + (1-a) \cdot E_{Test}[k, n] \quad (43)$$

où E_{Test} et E_{Ref} sont les caractéristiques d'excitation qui doivent être adaptées les unes aux autres et a est calculé à partir des constantes temporelles selon l'équation:

$$a = e^{-\frac{StepSize}{48000 \cdot \tau}} \quad (44)$$

3.1.1 Adaptation des niveaux

A partir des caractéristiques d'entrée filtrées par les filtres passe-bas P_{test} et P_{ref} on calcule un facteur de correction temporaire **LevCorr** avec l'équation:

$$LevCorr[n] = \left(\frac{\sum_{k=0}^{Z-1} \sqrt{P_{Test}[k, n] \cdot P_{Ref}[k, n]}}{\sum_{k=0}^{Z-1} P_{Test}[k, n]} \right)^2 \quad (45)$$

Si ce facteur de correction est supérieur à 1, le Signal de référence est divisé par le facteur de correction, sinon le signal d'essai est multiplié par le facteur de correction.

$$E_{L,Ref}[k, n] = E_{Ref}[k, n] / LevCorr[n] \quad | \quad LevCorr[n] > 1 \quad (46)$$

$$E_{L,Test}[k, n] = E_{Test}[k, n] \cdot LevCorr[n] \quad | \quad LevCorr[n] \leq 1 \quad (47)$$

3.1.2 Adaptation des caractéristiques

On calcule les facteurs de correction pour chaque canal en comparant les enveloppes temporelles des sorties de filtre du signal d'essai et du Signal de référence:

$$R[k, n] = \frac{\sum_{i=0}^n a[k]^i \cdot E_{L,Test}[k, n-i] \cdot E_{L,Ref}[k, n-i]}{\sum_{i=0}^n a[k]^i \cdot E_{L,Ref}[k, n-i] \cdot E_{L,Ref}[k, n-i]} \quad (48)$$

Les valeurs de \mathbf{a} sont calculées conformément à l'équation ci-dessus (équation (44)) à partir des constantes temporelles données par l'équation (41). Si $\mathbf{R}[\mathbf{k}, \mathbf{n}]$ est supérieur à 1, le facteur de correction pour le signal testé est $\mathbf{R}[\mathbf{k}, \mathbf{n}]^{-1}$ et le facteur de correction pour le Signal de référence est 1. Dans le cas contraire, le facteur de correction pour le Signal de référence est $\mathbf{R}[\mathbf{k}, \mathbf{n}]$ et le facteur de correction pour le signal d'essai est 1.

$$\begin{aligned} R_{Test}[k, n] &= \frac{1}{R[k, n]}, & R_{Ref}[k, n] &= 1 & \left| R[k, n] \geq 1 \right. \\ R_{Test}[k, n] &= 1, & R_{Ref}[k, n] &= R[k, n] & \left| R[k, n] < 1 \right. \end{aligned} \quad (49)$$

Si le dénominateur de (48) est nul ($\mathbf{R}[\mathbf{k}, \mathbf{n}]$ serait alors indéfini) et si le numérateur est plus grand que zéro, $\mathbf{R}_{Test}[\mathbf{k}, \mathbf{n}]$ vaut zéro et $\mathbf{R}_{Ref}[\mathbf{k}, \mathbf{n}]$ vaut un. Si le numérateur de (48) est également nul, les rapports $\mathbf{R}_{Test}[\mathbf{k}, \mathbf{n}]$ et $\mathbf{R}_{Ref}[\mathbf{k}, \mathbf{n}]$ sont copiés à partir de la bande de fréquences inférieure. S'il n'y a pas de bande de fréquences inférieure (à savoir si $\mathbf{k}=\mathbf{0}$) les rapports $\mathbf{R}_{Test}[\mathbf{k}, \mathbf{n}]$ et $\mathbf{R}_{Ref}[\mathbf{k}, \mathbf{n}]$ sont égaux à 1.

On fait la moyenne des facteurs de correction sur \mathbf{M} canaux de filtres et on les amortit temporellement (équation (50)) avec les mêmes constantes temporelles que ci-dessus (équations (41) à (44)). La largeur de la fenêtre de fréquences \mathbf{M} vaut 3 pour le modèle auditif fondé sur le banc de filtres, et 4 (version avancée) ou 8 (version de base) pour le modèle FFT.

$$\begin{aligned} PattCorr_{Test}[k, n] &= a \cdot PattCorr_{Test}[k, n-1] + (1-a) \cdot \frac{1}{M} \cdot \sum_{i=-M_1}^{M_2} R_{Test}[k+i, n] \\ PattCorr_{Ref}[k, n] &= a \cdot PattCorr_{Ref}[k, n-1] + (1-a) \cdot \frac{1}{M} \cdot \sum_{i=-M_1}^{M_2} R_{Ref}[k+i, n] \end{aligned} \quad (50)$$

$$\begin{cases} M_1 = M_2 = \frac{M-1}{2} & | M \text{ odd} \\ M_1 = \frac{M}{2} - 1, \quad M_2 = \frac{M}{2} & | M \text{ even} \end{cases}$$

Aux limites de l'échelle des fréquences où la fenêtre fréquentielle excéderait la gamme des bandes de filtres, la largeur de la fenêtre fréquentielle est réduite en conséquence:

$$M_1 = \min(M_1, k), \quad M_2 = \min(M_2, z - k - 1), \quad M = M_1 + M_2 + 1 \quad (51)$$

Les caractéristiques d'entrée adaptées au niveau sont pondérées avec les facteurs de correction correspondants $\mathbf{PattCorr}_{Test/Ref}[\mathbf{k}, \mathbf{n}]$ afin d'obtenir les caractéristiques adaptées spectralement:

$$E_{P,Ref}[k, n] = E_{L,Ref}[k, n] \cdot PattCorr_{Ref}[k, n] \quad (52)$$

$$E_{P,Test}[k, n] = E_{L,Test}[k, n] \cdot PattCorr_{Test}[k, n] \quad (53)$$

3.2 Modulation

A partir des *caractéristiques d'excitation non dégradées*, $E_2[k, n]$, on calcule une intensité acoustique en élevant l'excitation à la puissance 0,3. Cette valeur et la valeur absolue de sa déviation temporelle sont temporellement dégradées.

$$\bar{E}_{der}[k, n] = a \cdot \bar{E}_{der}[k, n-1] + (1-a) \cdot \frac{48000}{StepSize} \cdot \left| E_2[k, n]^{0,3} - E_2[k, n-1]^{0,3} \right| \quad (54)$$

$$\bar{E}[k, n] = a \cdot \bar{E}[k, n-1] + (1-a) \cdot E_2[k, n]^{0,3} \quad (55)$$

Les valeurs de a sont calculées comme en (44) à partir des constantes temporelles données par:

$$\tau = \tau_0 + \frac{100Hz}{f_c} \cdot (\tau_{100} - \tau_0) \quad \left| \begin{array}{l} \tau_{100} = 0,050 \text{ s} \\ \tau_0 = 0,008 \text{ s} \end{array} \right. \quad (56)$$

A partir des valeurs qui en résultent, on calcule \bar{E}_{der} et \bar{E} , la mesure de la modulation de l'enveloppe à chaque sortie de filtre:

$$Mod[k, n] = \frac{\bar{E}_{der}[k, n]}{1 + \bar{E}[k, n]/0,3} \quad (57)$$

Ultérieurement, on utilise également les valeurs de \bar{E} dans le calcul de la différence de modulation.

3.3 Intensité acoustique

Les caractéristiques spécifiques d'intensité acoustique du Signal testé et du Signal de référence sont calculées grâce à la formule:

$$N[k, n] = const \cdot \left(\frac{1}{s[k]} \cdot \frac{E_{Thres}[k]}{10^4} \right)^{0,23} \cdot \left[\left(1 - s[k] + \frac{s[k] \cdot E[k, n]}{E_{Thres}[k]} \right)^{0,23} - 1 \right] \quad (58)$$

donnée en Zwicker et Feldtkeller, 1967. L'intensité acoustique totale du Signal testé et du Signal de référence est la somme pour tous les canaux de filtre de toutes les valeurs d'intensité acoustique supérieures à zéro.

$$N_{total}[n] = \frac{24}{Z} \cdot \sum_{k=0}^{Z-1} \max(N[k, n], 0) \quad (59)$$

La constante de graduation est $const = 1,07664$ pour le modèle auditif périphérique FFT et $const = 1,26539$ pour le modèle auditif périphérique fondé sur le banc de filtres, afin d'obtenir une intensité acoustique globale de une sonie pour un son sinusoïdal de 40 dB_{SPL} à 1 kHz. L'indice de seuil s et l'excitation au seuil E_{Thres} sont calculés par les équations:

$$E_{Thres}[k] = 10^{0,364 \cdot \left(\frac{f}{1kHz} \right)^{-0,8}} \quad (60)$$

et

$$s[k] = 10^{\frac{1}{10} \left(-2 - 2,05 \cdot \text{atn} \left(\frac{f}{4kHz} \right) - 0,75 \cdot \text{atn} \left(\left(\frac{f}{1600Hz} \right)^2 \right) \right)} \quad (61)$$

respectivement.

NOTE – Du fait de l'existence de différents modèles auditifs périphériques, l'intensité acoustique calculée ici n'est pas identique à l'intensité acoustique telle qu'elle est définie dans ISO 532 Acoustics – Method for calculating loudness levels, 1975.

3.4 Calcul du signal d'erreur

Le signal d'erreur n'est calculé que dans le modèle FFT. On le calcule dans le domaine fréquentiel en prenant la différence entre les spectres d'intensité filtrés de l'oreille externe et de l'oreille moyenne du signal de référence et du signal d'essai (voir le § 2.1.4).

$$F_{noise}[k_f, n] = \|F_{eref}[k_f, n] - F_{etest}[k_f, n]\| \quad (62)$$

F_{noise} est représenté dans le domaine des hauteurs sonores par l'algorithme décrit au § 2.1.5.

Les sorties de cet algorithme, $P_{noise}[n, k]$, sont dénommées «Caractéristiques du bruit».

4 Calcul des variables de sortie de modèle

4.1 Aperçu général

TABLEAU 10

Aperçu des variables de sortie de modèle utilisées pour la prévision de la qualité audio de base

Variable de sortie de modèle (MOV)	Calculée dans le modèle auditif ...		Utilisée dans la version ...	
	FFT	Banc de filtres	De base	Avancée
WinModDiff1 _B	oui	non	oui	non
AvgModDiff1 _B	oui	non	oui	non
AvgModDiff2 _B	oui	non	oui	non
RmsModDiff _A	non	oui	non	oui
AvgNoiseLoud _B	oui	non	oui	non
RmsNoiseLoud _B	oui	non	oui	non
RmsNoiseLoudAsym _A	non	oui	non	oui
AvgLinDist _A	non	oui	non	oui
BandwidthRef _B	oui	non	oui	non
BandwidthTest _B	oui	non	oui	non
Total NMR _B	oui	non	oui	non
RelDistFrames _B	oui	non	oui	non
Segmental NMR _B	oui	non	non	oui
MFPD _B	oui	non	oui	non
ADB _B	oui	non	oui	non
EHS _B	oui	non	oui	oui

4.2 Différence de modulation

Les différences de modulation des enveloppes temporelles du Signal testé et du Signal de référence sont mesurées en calculant une différence de modulation locale pour chaque canal de filtre (équation (63)): où Mod_{test} et Mod_{Ref} sont déterminés par application de l'équation (57) au signal de référence R_{test} .

$$ModDiff[k, n] = w \cdot \frac{|Mod_{test}[k, n] - Mod_{Ref}[k, n]|}{offset + Mod_{Ref}[k, n]} \quad (63)$$

$$\begin{cases} w = 1.0 & |Mod_{test}[k, n] > Mod_{Ref}[k, n] \\ w = negWt & |Mod_{test}[k, n] < Mod_{Ref}[k, n] \end{cases}$$

La différence de modulation temporaire est la somme des différences de modulation locales sur tous les canaux de filtre (équation (64)).

$$ModDiff[n] = \frac{100}{Z} \sum_{k=0}^{Z-1} ModDiff[k, n] \quad (64)$$

Le seuil au repos est pris en compte par un facteur de pondération dépendant du niveau (équation (65) calculé à partir des caractéristiques d'excitation modifiées pour le signal de référence données par l'équation (55) et de la fonction de bruit interne définie par l'équation (36) pour le modèle auditif fondé sur le banc de filtres et l'équation (13) pour le modèle FFT.

$$TempWt[n] = \sum_{k=0}^{Z-1} \frac{\bar{E}_{ref}[k, n]}{\bar{E}_{ref}[k, n] + levWt \cdot E_{Thres}[k]} ^{0,3} \quad (65)$$

La moyenne temporelle des différences temporaires de modulation $ModDiff[n]$ qui utilise les facteurs de pondération $TempWt[n]$ est décrite au § 5.2 (*Moyenne temporelle*). Les valeurs des constantes $negWt$, $offset$ et $levWt$ sont données dans le Tableau 11.

TABLEAU 11

Variables de sortie de modèle dans l'estimation de la différence globale de modulation

MOV (Xxx=Win/Avg/Rms)	negWt	écart	levWt
$XxxModDiff1_B$	1	1	100
$XxxModDiff2_B$	0,1	0,01	100
$XxxModDiff_A$	1	1	1

4.2.1 RmsModDiff_A

La variable de sortie de modèle $RmsModDiff_A$ est la moyenne quadratique de la différence de modulation calculée à partir du modèle auditif fondé sur le banc de filtres. Voir le calcul de la moyenne temporelle au § 5.2.2 et les constantes dans le Tableau 11.

4.2.2 WinModDiff1_B

La variable de sortie de modèle $WinModDiff1_B$ est la moyenne avec fenêtrage de la différence de modulation calculée à partir du modèle auditif FFT. Voir le calcul de la moyenne temporelle au § 5.2.3 et les constantes dans le Tableau 11. Le facteur de pondération temporelle indiqué dans l'équation (65) n'est pas appliqué à cette variable.

4.2.3 AvgModDiff1_B et AvgModDiff2_B

Les variables de sortie de modèle $AvgModDiff1_B$ et $AvgModDiff2_B$ sont la moyenne linéaire de la différence de modulation calculée à partir du modèle auditif FFT. La différence entre $AvgModDiff2_B$ et $AvgModDiff1_B$ repose sur le choix des constantes. Voir le calcul de la moyenne temporelle au § 5.2.1 et les constantes dans le Tableau 11.

4.3 Intensité acoustique du bruit

Les variables de sortie du modèle sont des estimations de l'intensité partielle des distorsions ajoutées en présence du Signal de référence masquant. L'équation de l'intensité partielle (équation 66) sert à déterminer l'intensité spécifique du bruit selon [Zwicken et Feldtkeller, 1997] s'il n'y a pas de masque, et une valeur qui serait en quelque sorte un rapport entre le bruit et le masque si le bruit est très faible par rapport au masque.

L'intensité acoustique partielle du bruit se calcule avec l'équation:

$$NL[k, n] = \left(\frac{1}{s_{test}} \cdot \frac{E_{Thres}}{E_0} \right)^{0,23} \cdot \left[\left(1 + \frac{\max(s_{test} \cdot E_{test} - s_{ref} \cdot E_{ref}, 0)}{E_{Thres} + s_{ref} \cdot E_{ref} \cdot \beta} \right)^{0,23} - 1 \right] \quad (66)$$

où E_0 vaut toujours 1, E_{Thres} est la fonction de bruit interne $E_{Thres}[k]$ tel qu'elle est définie dans l'équation (36) et s se calcule avec la formule:

$$s = ThresFac_0 \cdot Mod[k, n] + S_0 \quad (67)$$

Sauf précisions contraires, on utilise comme entrées les *caractéristiques d'excitation spectralement adaptées* (voir le § 3.1): $E_{Test} = E_{P,Test}[k, n]$ et $E_{Ref} = E_{P,Ref}[k, n]$. Le coefficient β , qui détermine la quantité de masquage, se calcule de la façon suivante:

$$\beta = \exp\left(-\alpha \cdot \frac{E_{test} - E_{ref}}{E_{ref}}\right) \quad (68)$$

Les valeurs d'intensité de bruit temporaire ne sont pas prises en compte avant 50 ms après que l'intensité globale du canal de gauche ou du canal de droite ait dépassé une fois la valeur de $N_{Thres} = 0,1$ **one** pour le signal d'essai et le Signal de référence (voir le § 5.2.4.2).

Lors du calcul de la moyenne spectrale, les valeurs instantanées sont normalisées par le nombre de bandes de filtrage par bande critique et non pas par le nombre total de bandes de filtrages; en d'autres termes, le résultat du calcul de la moyenne spectrale est multiplié par le facteur 24.

Si l'intensité de bruit temporaire est inférieure à une valeur seuil de NL_{min} on la considère comme nulle.

TABLEAU 12

Variables de sortie de modèle pour l'estimation de l'intensité acoustique globale du bruit

MOV (Xxx=Win/Avg/Rms)	α	ThresFac ₀	S ₀	NL _{min}
$XxxMissingComponents_B$	1,5	0,15	1	0
$XxxNoiseLoud_B$	1,5	0,15	0,5	0
$XxxMissingComponents_A$	1,5	0,15	1	0
$XxxNoiseLoud_A$	2,5	0,3	1	0,1
$XxxLinDist_A$	1,5	0,15	1	0

4.3.1 RmsNoiseLoud_A

La variable de sortie de modèle $RmsNoiseLoud_A$ est la moyenne quadratique de l'intensité du bruit calculée à partir du modèle auditif fondé sur le banc de filtres. Voir le calcul de la moyenne temporelle au § 5.2.2 et les constantes dans le Tableau 12.

4.3.2 RmsMissingComponents_A

La variable de sortie de modèle $RmsMissingComponents_A$ est la moyenne quadratique de l'intensité du bruit calculée à partir du modèle auditif fondé sur le banc de filtres. Elle est calculée avec les caractéristiques d'excitation interverties du signal d'essai et du Signal de référence afin d'obtenir l'intensité des composantes du Signal de référence qui sont perdues dans le signal d'essai. Voir le calcul de la moyenne temporelle au § 5.2.2 et les constantes dans le Tableau 12.

4.3.3 RmsNoiseLoudAsym_A

La variable de sortie de modèle $RmsNoiseLoudAsym_A$ est la somme pondérée des carrés des moyennes d'intensité du bruit (§ 4.3.1) et de l'intensité des composantes de signal perdues (§ 4.3.2), les deux valeurs étant calculées à partir du modèle auditif fondé sur le banc de filtres.

$$RmsNoiseLoudAsym = RmsNoiseLoud + 0,5 \cdot RmsMissingComponents. \quad (69)$$

4.3.4 AvgLinDist_A

La variable de sortie de modèle $AvgLinDist_A$ est la mesure de l'intensité des composantes de signal perdues lors de l'adaptation spectrale du Signal testé et du Signal de référence. La référence en est l'excitation spectralement adaptée du Signal de référence et le signal d'essai en est l'excitation non adaptée du Signal de référence. Les valeurs de l'intensité locale du bruit sont pondérées avec les fréquences centrales de la bande de fréquences correspondante divisées par 1 kHz. Cette MOV est calculée à partir du modèle auditif fondé sur le banc de filtres. Voir le calcul de la moyenne temporelle au § 5.2.1 et les constantes dans le Tableau 12.

4.3.5 RmsNoiseLoud_B

La variable de sortie de modèle $RmsNoiseLoud_B$ est la moyenne quadratique de l'intensité du bruit calculée à partir du modèle auditif FFT. Voir le calcul de la moyenne temporelle au § 5.2.2 et les constantes dans le Tableau 12.

4.4 Largeur de bande

Ces valeurs de sortie de modèle sont des estimations de la largeur de bande moyenne du signal d'essai et du Signal de référence dans les raies FFT.

Pour chaque trame la largeur de bande locale $Bw_{Ref}[n]$ et $Bw_{Test}[n]$ est calculée selon le pseudo-code ci-dessous.

4.4.1 Pseudo-code

/* inputs */

FLevRef[], FlevelTest[] : niveau des sorties FFT en dB

/* outputs */

BwRef, BwTest : caractéristiques des sorties

/* intermediate values */

k : indice des raies FFT

ZeroThreshold : seuil de largeur de bande

```
ZeroThreshold = -1.0E-10;
BwRef = BwTst = 0.0;
for(k=921;k<1024;k++)
{
```

```

ZeroThreshold=max(ZeroThreshold,FLevelTst(k));
}

for (k = 920; k>=0; k--)
{
  if (FLevelRef[k] >= 10.0+ZeroThreshold)
  {
    BwRef = k+1;
  }
  break;
}

for (k = BwRef-1; k>=0; k--)
{
  if(FLeveltest[k] >= 5.0+ZeroThreshold)
  {
    BwTest=k+1;
    break;
  }
}
}

```

4.4.2 BandwidthRef_B et BandwidthTest_B

BandwidthRef_B est la moyenne linéaire de BwRef, et BandwidthTest_B est la moyenne linéaire de BwTest. Pour le calcul de la moyenne, seules les trames de BwRef > 346 sont prises en compte. Les trames de faible énergie au début et à la fin des éléments sont ignorées (voir le § 5.2.4.4). Voir le calcul de la moyenne temporelle au § 5.2.1.

4.5 Rapport bruit/masque (NMR)

Les valeurs de modèle suivantes sont calculées à partir des valeurs de bruit et de masque.

Le NMR local de la trame courante n est:

$$NMR_{local}[n] = 10 * \log_{10} \frac{1}{Z} \sum_{k=0}^{Z-1} \frac{P_{noise}[k,n]}{M[k,n]} \quad (70)$$

4.5.1 Total NMR_B

La variable de sortie de modèle $Total\ NMR_B$ est la moyenne linéaire du rapport bruit/masque.

$$NMR_{tot} = 10 * \log_{10} \frac{1}{N} \sum_n \left(\frac{1}{Z} \sum_{k=0}^{Z-1} \frac{P_{noise}[k,n]}{M[k,n]} \right) \quad (71)$$

Les trames de faible énergie au début et à la fin des éléments sont ignorées (voir le § 5.2.4.4).

4.5.2 Segmental NMR_A

La variable de sortie de modèle *Segmental NMR_A* est la moyenne linéaire du NMR local. Voir le calcul de la moyenne temporelle au § 5.2.1.

Les trames de faible énergie au début et à la fin des éléments sont ignorées (voir le § 5.2.4.4).

4.6 Relative Disturbed Frames $_B$

La variable de sortie de modèle *Relative Disturbed Frames $_B$* (abréviation: RelDistFrames $_B$) représente le nombre de trames ayant:

$$\max_{\forall k} \left(10 \cdot \log \left(\frac{P_{noise}[k, n]}{M[k, n]} \right) \right) \geq 1,5dB \quad k \in [0, Z - 1]$$

par rapport au nombre total de trames de l'élément.

Les trames de faible énergie au début et à la fin des éléments sont ignorées (voir le § 5.2.4.4).

4.7 Probabilité de détection

Les MOV définies dans ce paragraphe sont fondées sur $\tilde{E}[k, n]$ (bande k , trame n), qui sont les *caractéristiques d'excitation* $E[k, n]$ exprimées en dB:

$$\tilde{E}[k, n] = 10 \cdot \log_{10}(E[k, n]) \quad (72)$$

Pour chaque trame n :

Les calculs qui suivent sont effectués indépendamment pour chaque canal c (les valeurs de c sont gauche et droite). Les *caractéristiques logarithmiques d'excitation* sont $\tilde{E}_{ref}[k, n]$ pour le Signal de référence et $\tilde{E}_{test}[k, n]$ pour le Signal testé.

Pour chaque bande k :

- Calcul de l'excitation asymétrique moyenne.

$$L[k, n] = 0,3 \cdot \max(\tilde{E}_{ref}[k, n], \tilde{E}_{test}[k, n]) + 0,7 \cdot \tilde{E}_{test}[k, n] \quad (73)$$

- Calcul de la dimension du pas de détection réel s . La formule qui suit est une approximation de la différence de niveau juste identifiable mesurée par [Zwicker et Fastl, 1990].

Si $L[k, n] > 0$:

$$s[k, n] = \frac{5,95072 \cdot ((6,39468)/L[k, n])^{1,71332} + 9,01033 \cdot 10^{-11} \cdot L[k, n]^4 + 5,05622 \cdot 10^{-6} \cdot L[k, n]^3 - 0,00102438 \cdot L[k, n]^2 + 0,0550197 \cdot L[k, n] - 0,198719}{L[k, n]}$$

sinon

$$s[k, n] = 1,0 \cdot 10^{-30} \quad (74)$$

- Calcul de l'erreur signée e

$$e[k, n] = \tilde{E}_{ref}[k, n] - \tilde{E}_{test}[k, n] \quad (75)$$

- Si $\tilde{E}_{ref}[k, n] > \tilde{E}_{test}[k, n]$, alors la caractéristique de pente b vaut 4,0 sinon elle vaut 6,0. Ceci modélise l'effet suivant: un accroissement de l'énergie de signal du Signal testé par rapport au Signal de référence est plus frappant qu'une diminution.

- Calcul du facteur de graduation \mathbf{a} .

$$\mathbf{a}[k, n] = \frac{10^{\frac{\log_{10}(\log_{10}(2,0))}{b}}}{s[k, n]} \quad (76)$$

- Calcul de la probabilité de détection. L'équation (76) détermine le facteur de graduation \mathbf{a} de façon à ce que si $\mathbf{e}[k, n]$ est égal à $\mathbf{s}[k, n]$, $\mathbf{p}_c[k, n]$ devient $0,5$.

$$\mathbf{p}_c[k, n] = 1 - 10^{-(\mathbf{a}[k, n] \cdot \mathbf{e}[k, n]^b)} \quad (77)$$

- Calcul du nombre total de pas au dessus du seuil:

$$q_c[k, n] = \frac{|\text{INT}(\mathbf{e}[k, n])|}{s[k, n]} \quad (78)$$

- La probabilité de détection bilatérale est:

$$p_{\text{bin}}[k, n] = \max(p_{\text{left}}[k, n], p_{\text{right}}[k, n]) \quad (79)$$

- Le nombre de pas au dessus du seuil pour le canal bilatéral est:

$$q_{\text{bin}}[k, n] = \max(q_{\text{left}}[k, n], q_{\text{right}}[k, n]) \quad (80)$$

La probabilité globale de détection du canal \mathbf{c} de la trame \mathbf{n} est:

$$P_c[n] = 1 - \prod_{\forall k} (1 - p_c[k, n]) \quad (81)$$

où \mathbf{c} peut être *left*, *right* ou *bin*. Le nombre de pas au dessus du seuil pour le canal \mathbf{c} de la trame \mathbf{n} est:

$$Q_c[n] = \sum_{\forall k} q_c[k, n] \quad (82)$$

4.7.1 Probabilité de détection maximum filtrée (MFPD_B)

On calcule une version pondérée de la probabilité de détection pour chaque canal \mathbf{c} :

$$\tilde{P}_c[n] = (1 - c_0) \cdot P_c[n] + c_0 \cdot \tilde{P}_c[n - 1] \quad (83)$$

où $P_c[-1] = 0$. La constante c_0 dépend de *StepSize*:

$$c_0 = 0,9^{\text{StepSize}/1024} \quad (84)$$

c_0 réduit la sensibilité aux distorsions infimes.

On calcule la probabilité de détection maximum filtrée:

$$PM_c[n] = \max(PM_c[n - 1] \cdot c_1, \tilde{P}_c[n]) \quad (85)$$

où $PM_c[-1]$ est nul. La constante c_1 dépend de *StepSize*:

$$c_1 = 0,99^{\text{StepSize}/1024} \quad (86)$$

c_1 modélise l'effet suivant: les distorsions au début d'un extrait sonore sont moins graves qu'à la fin de cet extrait du fait du phénomène d'oubli. Il convient de noter que cette constante est utile pour la modélisation des essais d'écoute lors desquels les sujets ne sont pas autorisés à sélectionner des plus petites parties de l'extrait. Pour le présent modèle, étalonné avec des données provenant des essais d'écoute conformément à la Recommandation UIT-R BS.1116-1, c_1 doit être égal à 1,0.

La MOV *MFPD* est la valeur de $PM_{\text{bin}}[n]$ pour la dernière trame.

4.7.2 Bloc distordu moyen⁶ (ADB_B)

On compte le nombre de trames valides présentant une probabilité de détection du canal central $P_{\text{bin}}[n]$ supérieure à 0,5 ($n_{\text{distorted}}$).

On calcule pour toutes les trames valides le nombre total de pas au dessus du seuil du canal central $Q_{\text{bin}}[n]$:

$$Q_{\text{sum}} = \sum_{\forall n} Q_{\text{bin}}[n]$$

On calcule la distorsion du bloc moyen distordu, ADB:

- si $n_{\text{distorted}}$ égal zéro alors ADB = 0 (pas de distorsion audible);
- si $n_{\text{distorted}} > 0$ et $Q_{\text{sum}} > 0$ alors ADB = $\log_{10} ((Q_{\text{sum}}) / n_{\text{distorted}})$;
- si $n_{\text{distorted}} > 0$ et Q_{sum} égal zéro alors ADB = -0,5.

4.8 Structure harmonique de l'erreur

Un Signal de référence contenant des harmoniques forts (ex. clarinette basse, clavecin) a un spectre caractérisé par un certain nombre de pics régulièrement espacés séparés par des ventres profonds. Sous certaines conditions, le signal d'erreur peut hériter de cette structure. Par exemple, un bruit mélangé à un tel signal a plus de chances de ne pas être masqué quand le signal est faible dans les ventres du spectre. Le spectre de l'erreur qui en résulte aurait alors une structure semblable à celle du spectre original mais avec un écart en fréquence pour correspondre aux emplacements des ventres. De cette structure peut résulter une distorsion dont les qualités tonales pourraient augmenter la saillance de l'erreur.

L'erreur est définie comme étant la différence des signaux de référence et des signaux traités dans chaque spectre logarithmique. La structure d'excitation tirée du modèle psychoacoustique n'est pas utilisée ici parce que la transformation non linéaire de Bark, appliquée aux fréquences, estomperait la structure harmonique.

4.8.1 EHS_B

On mesure l'amplitude de la structure harmonique en identifiant et en mesurant le pic le plus élevé dans le spectre de la fonction d'autocorrélation. Chaque corrélation est calculée comme le cosinus de l'angle compris entre deux vecteurs conformes à la formule suivante, où \vec{F}_0 est le vecteur d'erreur et \vec{F}_t est le même vecteur retardé d'une certaine grandeur.

$$C = \frac{\vec{F}_0 \cdot \vec{F}_t}{|\vec{F}_0| \cdot |\vec{F}_t|} \quad (87)$$

Le retard maximal pour obtenir la fonction d'autocorrélation est la plus grande puissance de deux qui est plus petite que la moitié du nombre de la composante fréquentielle de transformation FFT correspondant à 18 kHz.

Par exemple, à une fréquence d'échantillonnage de 48 kHz et dans une fenêtre FFT ayant un effectif de 2 048 échantillons, la composante FFT correspondant à 18 kHz est égale à $(18/24) \times 1024 = 768$. Le retard maximal sera donc de 384. Le nombre de retards réel sera 256, qui est la plus grande puissance de deux inférieure à 384. La première valeur de la fonction de corrélation sera obtenue par alignement de $F_t[0]$ sur $F_0[0]$ et la dernière valeur par alignement de $F_t[0]$ sur $F_0[255]$.

Le vecteur résultant des corrélations est intégré dans une fenêtre de Hann normalisée et, après suppression de la composante continue par soustraction de la valeur moyenne, on calcule un spectre avec transformation FFT. Le pic maximal de ce spectre correspond à la fréquence dominante dans la fonction d'autocorrélation. La valeur moyenne multipliée par 1000.0 de ce pic maximal d'une trame à l'autre multipliée par 1000.0 est la variable de structure harmonique d'erreur (EHS).

⁶ Le terme de «bloc» est équivalent à celui de «trame» dans ce contexte.

5 Moyennes

5.1 Calcul de la moyenne spectrale

Sauf indications contraires dans les descriptions des variables de sortie de modèle (§ 4), on utilise l'algorithme suivant pour obtenir la moyenne des valeurs locales sur les bandes de fréquences.

5.1.1 Moyenne linéaire

On calcule la valeur de la moyenne linéaire avec:

$$AvgS = \frac{1}{Z} \cdot \sum_{k=0}^{Z-1} S[k] \quad (88)$$

où S est le nom de la variable de sortie de modèle et Z le nombre de groupes de fréquences.

5.2 Calcul de la moyenne temporelle

Sauf indications contraires dans les descriptions des variables de sortie de modèle (§ 4), on utilise un ou plusieurs des algorithmes suivants pour obtenir la moyenne des valeurs temporaires dans le temps. Le facteur de pondération temporelle est désigné (s'il est appliqué) par le symbole W et Z est le nombre de bandes de fréquences.

5.2.1 Moyenne linéaire

On calcule la valeur de la moyenne linéaire (préfixe «Avg») avec:

$$AvgX = \frac{1}{N} \cdot \sum_{n=0}^{N-1} X[n] \quad (89)$$

où X est le nom de la variable de sortie de modèle et N le nombre d'échantillons temporels pour lesquels on a calculé les valeurs temporaires de X .

Si on applique une pondération temporelle (voir le § 4.2 *Différence de modulation*), on calcule la moyenne linéaire avec:

$$AvgX = \frac{\sum_{n=0}^{N-1} W[n] \cdot X[n]}{\sum_{n=0}^{N-1} W[n]} \quad (90)$$

5.2.2 Moyenne quadratique

On calcule la moyenne quadratique (préfixe «Rms») selon l'équation:

$$RmsX = \sqrt{\frac{1}{N} \cdot \sum_{n=0}^{N-1} X[n]^2} \quad (91)$$

où X est le nom de la variable de sortie de modèle et N le nombre d'échantillons temporels pour lesquels les valeurs temporaires de X ont été calculées.

Si on applique une pondération temporelle (voir le § 4.2 *Différence de Modulation*), la moyenne quadratique se calcule de la façon suivante:

$$RmsX = \sqrt{Z} \cdot \sqrt{\frac{\sum_{n=0}^{N-1} W[n]^2 \cdot X[n]^2}{\sum_{n=0}^{N-1} W[n]^2}} \quad (92)$$

5.2.3 Moyenne avec fenêtrage

La valeur de la moyenne avec fenêtrage (préfixe «Win») se calcule avec l'équation:

$$WinX = \sqrt{\frac{1}{N-L+1} \cdot \sum_{n=L-1}^{N-1} \left(\frac{1}{L} \cdot \sum_{i=0}^{L-1} \sqrt{X[n-i]} \right)^4} \quad (93)$$

où X est le nom de la variable de sortie de modèle, N le nombre d'échantillons temporels pour lesquels les valeurs temporaires de X ont été calculées et L la longueur des fenêtres temporelles dans les échantillons temporels. La longueur de la fenêtre est approximativement 100 ms, ce qui signifie que L vaut **4** pour le modèle auditif FFT et **25** pour le modèle auditif fondé sur le banc de filtres.

5.2.4 Sélection des trames

5.2.4.1 Moyenne retardée

Pour les variables de sortie de modèle qui utilisent ce critère, les valeurs calculées pendant la première demi-seconde de la mesure ne sont pas prises en compte dans la moyenne temporelle. On utilise la *Moyenne retardée* pour toutes les variables de sortie de modèle suivantes:

WinModDiff1, AvgModDiff1, AvgModDiff2, RmsNoiseLoudness, RmsNoiseLoudAsym, RmsModDiff, AvgLinDist.

5.2.4.2 Seuil d'intensité

Pour les variables de sortie de modèle qui utilisent ce critère, toutes les valeurs temporaires calculées jusqu'à 50 ms après que l'intensité globale d'un des canaux correspondants a atteint une fois une valeur de N_{Thres} sonie pour le signal d'essai et le Signal de référence ne sont pas prises en compte dans la moyenne temporelle. On n'utilise le *Seuil d'intensité* que pour les variables de sortie de modèle décrites au § 4.3.

5.2.4.3 Seuil d'énergie

Si l'énergie de la moitié la plus récente d'une trame de 2048 échantillons est inférieure à 8000* dans le canal mono ou dans les deux canaux droite et gauche de la référence et les données de Test, la trame est ignorée. Les trames présentent un recouvrement de 50% et seule la moitié de la trame contenant des données nouvelles est évaluée. L'application de ce critère permet d'éviter de traiter des trames n'ayant que peu d'énergie.

Ce critère n'est utilisé que pour la variable de sortie de modèle décrite au § 4.8.

5.2.4.4 Limite de données

Si le fichier traité contient du bruit avant ou après les données du fichier de référence, l'erreur relative peut être très importante puisque le niveau de référence est zéro. Si cette erreur est considérée comme un artefact, on peut l'ignorer en appliquant le critère de rejet de limite de données.

A la première ouverture des fichiers, on identifie l'emplacement du début et de la fin des données réelles dans le fichier de référence. Le début ou la fin des données est défini comme premier emplacement, selon que l'on analyse à partir du début ou de la fin du fichier, où la somme des valeurs absolues sur cinq échantillons successifs est supérieure à 200 dans l'un des canaux audio correspondant. Les trames qui sortent entièrement de cette fourchette sont en conséquence ignorées.

On utilise ce critère pour les variables de sortie de modèle décrites aux § 4.4 à 4.6 et 4.8.

* Ce nombre se rapporte à des données d'entrée en format d'entiers signés de 16 bit dans une étendue de -32 768 à 32 767, comme cela est le cas sur un disque compact.

5.3 Moyenne sur les canaux audio

Sauf indications différentes, dans le cas de signaux stéréo, les variables MOV des canaux de gauche et de droite sont calculées linéairement après calcul moyennage temporel.

6 Estimation de la qualité audio de base perçue

On estime la *qualité audio de base perçue* en transformant plusieurs variables de sortie de modèle en un seul chiffre grâce à une structure de réseau neuronal artificiel avec une couche cachée.

6.1 Réseau neuronal artificiel

La fonction d'activation du réseau neuronal est une sigmoïde asymétrique:

$$\text{sig}(x) = \frac{1}{1 + e^{-x}} \quad (94)$$

Le réseau utilise I entrées et J nœuds dans la couche cachée. La transformation est définie par un ensemble de facteurs de graduation d'entrée $a_{\min}[i]$, $a_{\max}[i]$, un ensemble de pondération d'entrée $w_x[I, i]$, un ensemble de pondération de sortie $w_y[j]$ et deux facteurs de graduation de sortie b_{\min} et b_{\max} . Les entrées sont transformées en un *indice de distorsion*:

$$DI = w_y[j] + \sum_{j=0}^{J-1} \left(w_y[j] \cdot \text{sig} \left(w_x[I, j] + \sum_{i=0}^{I-1} w_x[i, j] \cdot \frac{x[i] - a_{\min}[i]}{a_{\max}[i] - a_{\min}[i]} \right) \right) \quad (95)$$

qui est directement lié à l'estimation de la *qualité audio de base perçue* en termes d'une *note différentielle objective* (ODG). La relation entre l'*indice de distorsion* et la *note différentielle objective* est donnée par la formule:

$$ODG = b_{\min} + (b_{\max} - b_{\min}) \cdot \text{sig}(DI) \quad (96)$$

6.2 Version de base

La version de base n'utilise que le modèle auditif FFT. Elle utilise les variables de sortie de modèle suivantes: $BandwidthRef_B$, $BandwidthTest_B$, $Total\ NMR_B$, $WinModDiff1_B$, ADB_B , EHS_B , $AvgModDiff1_B$, $AvgModDiff2_B$, $RmsNoiseLoud_B$, $MFPD_B$ et $RelDistFrames_B$. Ces 11 variables de sortie de modèle sont transformées en un indice de qualité unique par un réseau neuronal décrit au § 6.1 (*Réseau Neuronal Artificiel*) avec trois nœuds dans la couche cachée. On trouvera dans les Tableaux 13 à 17, les paramètres de la transformation.

TABLEAU 13

Variables de sortie de modèle utilisées dans la version de base

Variable de sortie de modèle (MOV)	Objet
WinModDiff1 _B	Changements de modulation (lié à la rugosité)
AvgModDiff1 _B	
AvgModDiff2 _B	
RmsNoiseLoud _B	Intensité de la distorsion
BandwidthRef _B	Distorsions linéaires (réponse en fréquence, etc.)
BandwidthTest _B	
RelDistFrames _B	Fréquence des distorsions audibles
Total NMR _B	Rapport bruit/masque
MFPD _B	Probabilité de détection
ADB _B	
EHS _B	Structure harmonique de l'erreur

TABLEAU 14

Facteurs de graduation pour les entrées de la version de base

indice (i)	MOV (x[i])	$a_{\min}[i]$	$a_{\max}[i]$
0	BandwidthRef _B	393,916656	921
1	BandwidthTest _B	361,965332	881,131226
2	Total NMR _B	-24,045116	16,212030
3	WinModDiff1 _B	1,110661	107,137772
4	ADB _B	-0,206623	2,886017
5	EHS _B	0,074318	13,933351
6	AvgModDiff1 _B	1,113683	63,257874
7	AvgModDiff2 _B	0,950345	1145,018555
8	RmsNoiseLoud _B	0,029985	14,819740
9	MFPD _B	0,000101	1
10	RelDistFrames _B	0	1

TABLEAU 15

Pondérations pour les nœuds d'entrée de la version de base

indice (i)	MOV (x[i])	nœud 1 ($w_x[i,0]$)	nœud 2 ($w_x[i,1]$)	nœud 3 ($w_x[i,2]$)
0	BandwidthRef _B	-0,502657	0,436333	1,219602
1	BandwidthTest _B	4,307481	3,246017	1,123743
2	Total NMR _B	4,984241	-2,211189	-0,192096
3	WinModDiff1 _B	0,051056	-1,762424	4,331315
4	ADB _B	2,321580	1,789971	-0,754560
5	EHS _B	-5,303901	-3,452257	-10,814982
6	AvgModDiff1 _B	2,730991	-6,111805	1,519223
7	AvgModDiff2 _B	0,624950	-1,331523	-5,955151
8	RmsNoiseLoud _B	3,102889	0,871260	-5,922878
9	MFPD _B	-1,051468	-0,939882	-0,142913
10	RelDistFrames _B	-1,804679	-0,503610	-0,620456
11	bias	-2,518254	0,654841	-2,207228

TABLEAU 16

Pondération pour les nœuds de sortie de la version de base

nœud 1 ($w_y[0]$)	nœud 2 ($w_y[1]$)	nœud 3 ($w_y[2]$)	écart ($w_y[3]$)
-3,817048	4,107138	4,629582	-0,307594

TABLEAU 17

Facteurs de graduation pour la sortie de la version de base

	b_{\min}	b_{\max}
ODG	-3,98	0,22

6.3 Version avancée

La *version avancée* utilise le modèle auditif fondé sur le banc de filtres et le modèle auditif FFT. Elle utilise les variables de sortie de modèle $RmsModDiff_A$, $RmsNoiseLoudAsym_A$, $AvgLinDist_A$, $Segmental\ NMR_B$ et EHS_B . Ces 5 variables de sortie de modèle sont transformées en un indice de qualité unique par un réseau neuronal décrit au § 6.1 (*Réseau Neuronal Artificiel*) avec cinq nœuds dans la couche cachée. On trouvera dans les Tableaux 18 à 22, les paramètres de la transformation.

TABLEAU 18

Variables de sortie de modèle utilisées dans la version avancée

Variable de sortie de modèle (MOV)	objet
$RmsNoiseLoudAsym_A$	Intensité de la distorsion
$RmsModDiff_A$	Changements de modulation (lié à la rugosité)
$AvgLinDist_A$	Distorsions linéaires (réponse en fréquence etc.)
$Segmental\ NMR_B$	Rapport bruit/masque
EHS_B	Structure harmonique de l'erreur

TABLEAU 19

Facteurs de graduation pour les nœuds d'entrée de la version avancée

indice (i)	MOV ($x[i]$)	$a_{\min}[i]$	$a_{\max}[i]$
0	$RmsModDiff_A$	13,299	2166,500
11	$RmsNoiseLoudAsym_A$	0,041	13,243
12	$AvgLinDist_A$	0,025	14,225
13	$Segmental\ NMR_B$	-25,019	13,467
14	EHS_B	0,062	10,227

TABLEAU 20

Pondérations pour les entrées de la version avancée

index (i)	MOV ($x[i]$)	node 1 ($w_x[i,0]$)	node 2 ($w_x[i,1]$)	node 3 ($w_x[i,2]$)	node 4 ($w_x[i,3]$)	node 5 ($w_x[i,4]$)
0	RmsModDiff _A	21.212	-39.913	-1.383	-14.545	-0.321
1	RmsNoiseLoudAsym _A	-8.982	19.956	0.935	-1.687	-3.239
2	Segmental NMR _B	1.634	-2.878	-7.443	5.607	-1.783
3	EHS _B	6.104	19.587	-0.240	1.088	-0.511
4	AvgLinDist _A	11.556	3.892	9.720	-3.287	-11.031
5	bias	1.331	2.686	2.097	-1.328	3.087

TABLEAU 21

Pondération pour les nœuds de sortie de la version avancée

noeud 1 ($w_x[i,0]$)	noeud 2 ($w_x[i,1]$)	noeud 3 ($w_x[i,2]$)	noeud 4 ($w_x[i,3]$)	noeud 5 ($w_x[i,4]$)	écart ($w_y[4]$)
-4,697	-3,290	7,005	6,652	4,009	-1,360

TABLEAU 22

Facteurs de graduation pour la sortie de la version avancée

	b_{\min}	b_{\max}
ODG	-3,98	0,22

7 Conformité des mises en oeuvre

7.1 Généralités

Ce chapitre propose un ensemble d'éléments de tests pour contrôler la conformité de la mise en oeuvre de la méthode.

7.2 Sélection

Les éléments de tests ont été sélectionnés dans la base de données 3 (DB3), utilisées pour la validation des modèles. Afin de simplifier les tests, on a défini un sous-ensemble des 84 éléments de DB3. Ce sous-ensemble contient 20 éléments. Le critère principal de cette sélection fut que les valeurs de MOV et de DI (*Indice de distorsion*) couvrent une large gamme.

7.3 Réglages pour les tests de conformité

Les éléments de tests sont disponibles auprès de l'UIT sous forme de fichiers .WAV (format Microsoft RIFF). Tous les éléments sont échantillonnés à 48 kHz, 16 bit PCM. Les signaux de référence et de tests fournis par l'UIT sont déjà adaptés les uns aux autres quant au temps et au niveau; il n'y a donc pas besoin de compensation en gain ou en retard. L'algorithme de mesure doit être réglé pour un niveau d'écoute de 92 dB SPL.

7.4 Intervalle de tolérance acceptable

Afin d'être conforme à la recommandation, les valeurs calculées de DI doivent reproduire les valeurs données dans les Tableaux 23 et 24, avec une tolérance inférieure à $\pm 0,027$ pour tous les éléments de test. Si une mise en œuvre ne donnent pas des résultats situés dans cette fourchette de tolérance, elle n'est pas conforme à cette Recommandation.

7.5 Éléments de tests

Les tableaux qui suivent donnent le nom des éléments de référence et de tests⁸, les numéros de piste et les valeurs de DI qui en résultent. Le Tableau 23 concerne la version de base, le Tableau 24 la version avancée.

TABLEAU 23

Éléments de tests et valeurs DI qui en résultent pour la version de base

Élément	DI	ODG	Élément	DI	ODG	Élément	DI	ODG
acodsna.wav	1.304	-0.676	fcodtr2.wav	-0.045	-1.927	lcodhrp.wav	1.041	-0.876
bcodtri.wav	1.949	-0.304	fcodtr3.wav	-0.715	-2.601	lcodpip.wav	1.973	-0.293
ccodsax.wav	0.016	-1.863	gcodcla.wav	1.781	-0.386	mcodcla.wav	-0.436	-2.331
dcodryc.wav	1.648	-0.458	hcodryc.wav	2.291	-0.166	ncodsfe.wav	3.135	0.045
ecodsmg.wav	1.731	-0.412	hcodstr.wav	2.403	-0.128	scodclv.wav	1.689	-0.435
fcodsb1.wav	0.677	-1.195	icodsna.wav	-3.029	-3.786			
fcodtr1.wav	1.419	-0.598	kcodsme.wav	3.093	0.038			

TABLEAU 24

Éléments de tests et valeurs DI qui en résultent pour la version avancée

Élément	DI	ODG	Élément	DI	ODG	Élément	DI	ODG
acodsna.wav	2.392	-0.132	fcodtr3.wav	-0.501	-2.395	mcodcla.wav	1.364	-0.635
bcodtri.wav	1.830	-0.361	gcodcla.wav	2.027	-0.269	ncodsfe.wav	1.921	-0.316
ccodsax.wav	1.654	-0.455	hcodryc.wav	1.826	-0.363	scodclv.wav	1.893	-0.330
dcodryc.wav	1.764	-0.394	hcodstr.wav	1.990	-0.285			
ecodsmg.wav	1.490	-0.552	icodsna.wav	-3.245	-3.823			
fcodsb1.wav	1.918	-0.318	kcodsme.wav	1.972	-0.293			
fcodtr1.wav	1.333	-0.657	lcodhrp.wav	1.337	-0.654			
fcodtr2.wav	0.333	-1.533	lcodpip.wav	2.093	-0.241			

⁷ Pour atteindre cette précision, utiliser une arithmétique IEEE en virgule flottante.

⁸ Les noms des éléments de référence correspondants sont calculés par remplacement de la sous-chaîne «cod» dans les noms des éléments de test par la sous-chaîne «ref». Par exemple, l'élément de référence pour le fichier «bcodtri.wav» devient «breftri.wav».

APPENDICE 1 DE L'ANNEXE 2

Processus de validation**1 Généralités**

En 1994, l'UIT-R a adopté la Question UIT-R 210/10 «Méthode objective d'évaluation de la qualité perceptuelle» et un Groupe de travail a été mis sur pied. Une des premières actions fut de lancer un appel à propositions, qui reçut six réponses proposant un modèle.

Beaucoup de travail fut nécessaire pour définir les procédures du processus de validation. On estima nécessaire de compiler une première base de données, DB1, composée de matériaux provenant des essais d'écoute déjà effectués. L'intérêt principal étant la qualité audio moyenne et haute, seuls les résultats des essais d'écoute conformes à la Recommandation UIT-R BS.1116 furent pris en considération. Les matériaux de ces essais étaient des matériaux de radiodiffusion critiques pour des codecs à faible débit binaire comme MPEG1 Layer II, MPEG1 Layer III, Dolby AC2, Mini Disc, et NICAM. On créa la base de données 1 pour donner aux créateurs des modèles une plate-forme commune, composée de matériaux couvrant une large gamme de dégradations, divers codecs et une dégradation due à des codecs en cascade. On trouvera dans l'Appendice 2 de l'Annexe 2 une description détaillée des essais compilés dans la base de données 1.

Il était évident qu'une méthode de mesure objective de la qualité du son perçu qui imiterait le comportement humain ne pouvait être validée que sur une base de données contenant les résultats d'essais subjectifs. Une validation appropriée exige une base de données fondée sur des matériaux inconnus. C'est pourquoi il fut nécessaire d'effectuer des nouveaux essais d'écoute. La méthode de mesure devant idéalement cibler tout type d'artefact pouvant apparaître dans les applications de radiodiffusion, il fallait intégrer non seulement les artefacts de codage, mais aussi des artefacts plus traditionnels comme la distorsion et le bruit. Les bases de données 2 et 3 furent créées respectivement en 1996 et 1997 pour satisfaire à ces exigences. Outre les codecs déjà intégrés dans DB1, on intégra Dolby AC-3 et AAC. On trouvera des détails complémentaires dans l'Appendice 2 de l'Annexe 2.

La validation devait prendre en compte les incertitudes, souvent présentées comme des intervalles de confiance, inhérentes aux essais d'écoute subjective. La taille de l'intervalle de confiance dépend d'un certain nombre de facteurs. Les plus importants sont: l'expérience des sujets, les procédures d'entraînement, le contexte dans lequel les éléments de test sont présentés, et le nombre de sujets.

L'adaptation et la validation de la méthode objective proposée dans cette Recommandation sont fondées sur un «auditeur expert moyen». Pour définir «l'auditeur expert moyen», on utilise les valeurs moyennes des évaluations de qualité subjectives et les intervalles de confiance à 95%.

Les essais d'écoute subjective sont très sensibles à différents facteurs qui ont une influence sur les résultats. Les SDG des bases de données 2 et 3 furent produites sur trois sites d'essais différents, et un certain nombre d'études ont cherché à savoir si les données pouvaient vraiment être associées. Ces études ne sont pas toutes parvenues à des résultats identiques mais il apparut raisonnable de fusionner les données et c'est cette base de données fusionnées qui servit de base à la validation.

Le processus de validation s'est effectué en trois phases:

- Phase 1: Phase de compétition
- Phase 2: Phase de collaboration
- Phase 3: Choix final

Ces phases sont décrites en détail dans les paragraphes qui suivent.

2 Phase de compétition

Six méthodes (DIX, NMR, PAQM, PERCEVAL, POM, TTA) ont été proposées pour la mesure objective de la qualité du son perçu et il fut décidé de comparer les performances de ces méthodes avec la base de données 2 et un sous-ensemble de la base de données 1. La base de données 2 fut générée début 1996. Le choix final des matériaux d'essai fut le résultat des efforts conjoints de SR (Suède) et de la BBC (Royaume-Uni). Les essais d'écoute furent effectués à NRK en Norvège, DR au Danemark et NHK au Japon. L'analyse statistique des données de ces essais fut préparée par

Deutsche Telekom (Allemagne) et Teracom (Suède). Lors de la Phase 1, les données objectives étaient générées sur un site neutre (Swisscom, Suisse). Les créateurs des modèles reçurent alors la première moitié de la base de données 2 pour adaptation finale des méthodes (Phase 2). Enfin, des nouvelles notes différentielles objectives furent générées chez Swisscom.

L'analyse des performances des méthodes fut menée par Teracom (Suède) et par les créateurs eux-mêmes. Les résultats de certaines méthodes proposées montraient une forte corrélation avec les SDG, mais un consensus fut néanmoins trouvé pour dire qu'aucune des méthodes ne satisfaisait aux exigences des utilisateurs. Une étude indépendante a montré qu'aucune des méthodes proposées n'était de façon significative meilleure que les autres. Il fut donc décidé de développer une méthode de mesure améliorée conjointement par tous les créateurs. Les performances de la nouvelle méthode devaient être comparées avec une des méthodes déjà en place dénommée modèle B3.

3 Phase de collaboration

La phase de collaboration était fondée sur l'idée suivante: associer les meilleurs éléments de chaque méthode dans une nouvelle méthode unique. Pour mieux satisfaire aux besoins des utilisateurs, il fut décidé de développer deux versions de la méthode: une adaptée aux réalisations en temps réel, et une autre, demandant plus de puissance de calcul, pour obtenir une plus grande précision.

La procédure de validation des deux nouvelles méthodes fut mise au point de la même façon que pour la phase de compétition. Il fallait créer une nouvelle base de données (DB3). Les éléments et conditions furent arrêtés au printemps 1997 et compilés à SR, Swisscom et BBC. On trouvera dans l'Appendice 2 de l'Annexe 2 une description complète de la base de données. Les essais d'écoute subjectifs eurent lieu sur trois sites d'essai, Deutsche Telekom, NHK et SR. Tous les sites ont appliqué la «méthode en double aveugle à référence cachée et stimulus triple», décrite dans la Recommandation UIT-R BS.1116. Les résultats des essais d'écoute ont été collationnés en Suède. Une analyse statistique complète des résultats des essais d'écoute fut effectuée par Teracom et d'autres parties. Après cette analyse, certains auditeurs furent exclus de la suite de l'évaluation. On associa les résultats des sites d'essai pour créer la base de données 3.

A l'automne 1997, 52 éléments de la base de données furent donnés aux créateurs. Les nouvelles méthodes furent adaptées à ces nouvelles données. Comme plusieurs paramètres donnaient des résultats similaires le choix final fut retardé aussi longtemps que possible. Enfin, en Suisse, on utilisa les 32 éléments restants pour valider les nouvelles méthodes sur un ensemble de données «inconnu».

En outre, les résultats d'un nouvel essai d'écoute, mené par CRC (Canada) servirent à la validation des nouvelles méthodes sur des matériaux «inconnus». Les processus de choix et de vérification sont décrits dans les paragraphes qui suivent.

4 Vérification

On a effectué des essais complets des 18 versions spécifiées de la méthode de mesure objective. Les critères de sélection et les résultats des comparaisons entre les SDG et les résultats obtenus par les 18 versions de la méthode de mesure sont décrits dans ce paragraphe. L'objectif était de choisir et de vérifier les versions optimales qui seraient recommandées à l'UIT.

Critères de choix

Le critère le plus évident pour valider une méthode objective est la corrélation entre les résultats subjectifs et objectifs. En outre, on a introduit pour la validation deux critères supplémentaires qui prennent en compte la fiabilité des valeurs moyennes – la valeur de l'erreur absolue (AES) et les caractéristiques de tolérance.


La valeur de l'erreur absolue (AES), introduite pour relier la précision du modèle à la précision du test d'écoute, se définit par l'expression suivante:

$$AES = 2 * \sqrt{\frac{\sum ((ODG - SDG) / CI)^2}{N}} \quad \text{si } CI < 0,25 \text{ alors } CI = 0,25 \text{ où}$$

CI est l'intervalle de confiance

Les caractéristiques de tolérance sont conçues pour permettre diverses déviations des ODG par rapport aux SDG aux extrémités supérieure et inférieure de l'échelle des dégradations. La gamme tolérée dépend des intervalles de confiance des tests d'écoute. Cette gamme se limite à une valeur minimum de 0,25 graduations. On utilise la distance entre les ODG hors caractéristiques de tolérance et les caractéristiques de tolérance pour évaluer la qualité de la méthode de mesure.

FIGURE 12
Caractéristiques de tolérance, intervalle de confiance $CI \geq 0,25$



1387-12

4.1 Comparaison des valeurs de SDG et de ODG

Les mesures objectives ont été divisées en trois phases. Lors de la Phase 1, les 84 éléments de tests étaient inconnus de tout le monde, sauf du groupe de sélection. Lors de la Phase 2, des informations furent dévoilées sur 52 éléments. Ces informations étaient constituées des valeurs de SDG et des extraits sonores. Lors de la Phase 3 on a utilisé cette connaissance pour optimiser les performances des versions de la méthode. Il convient de noter que, par rapport à la Phase 1, quatre versions supplémentaires ont été évaluées lors de la Phase 3. Les valeurs de SDG présentées étaient calculées à partir de données générées par 75 sujets qualifiés.

Il existe diverses méthodes pour évaluer la façon dont les ODG sont corrélés aux SDG. Il n'y a malheureusement pas de valeur unique qui reflète la totalité des performances. On doit donc prendre en considération un certain nombre d'aspects. On trouvera les corrélations au § 4.2 et les valeurs de l'erreur absolue (AES) au § 4.3. Le Modèle B3 est un des modèles testés par l'UIT-R en 1996 et il avait été décidé que les diverses nouvelles versions devaient être comparées à ce modèle antérieur.

4.2 Corrélation

Les chiffres de corrélation de la Phase 1 et de la Phase 3 sont représentés sur la Figure 13 (84 éléments) et la Figure 14 (32 éléments).

FIGURE 13
Corrélation entre les SDG et les ODG. Les 84 éléments sont intégrés





FIGURE 14
 Corrélation entre les SDG et les ODG. Les 32 éléments non diffusés sont intégrés



4.3 Valeurs de l'erreur absolue (AES)

Un modèle qui produit en moyenne des valeurs d'ODG dans l'intervalle de confiance des SDG aura une valeur AES proche de 2. On trouvera dans la Figure 15 et la Figure 16 un résumé des valeurs AES.

FIGURE 15
AES des différentes versions. Les 84 éléments sont intégrés





FIGURE 16
 AES des différentes versions. Les 32 éléments non diffusés sont intégrés



1387-16


4.4 Comparaison des ODG et de l'intervalle de confiance

La plupart des versions ont des performances similaires, comme on pouvait probablement s'y attendre. De nombreuses représentations ont été présentées lors de la réunion mais dans la présente Recommandation le répertoire est limité. On trouvera plus de détails dans le rapport complet des essais de vérification.

Les Figures 17 à 22 sont les représentations, pour le Modèle B3 et les versions FftNnODG1 et CombNnODG3 du modèle, des moyennes de SDG, de l'intervalle de confiance et des ODG pour les 32 éléments non diffusés.

FIGURE 17


Modèle B3: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG pour les 32 éléments non diffusés



1387-17

FIGURE 18


FFTNnODG1: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG après la Phase 3 pour les 32 éléments non diffusés



1387-18

FIGURE 19

CombNnODG3: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG après la Phase 3 pour les 32 éléments non diffusés




1387-19

Les Figures 20 et 21 sont des représentations similaires, mais pour les 84 éléments de la Phase 3. En outre, la Figure 22 est une illustration des performances de la version CombNnODG3.

FIGURE 20


Modèle B3: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG pour les 84 éléments



1387-20

FIGURE 21


FFTNnODG1: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG pour les 84 éléments lors de la Phase 3



1387-21

FIGURE 22

CombNnODG3: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG pour les 84 éléments lors de la Phase 3



1387-22

4.5 Comparaison des ODG et de l'intervalle de confiance (tolérance)

L'UIT-R a défini une exigence pour l'utilisateur cible que l'on peut représenter par l'intervalle de confiance. Les exigences cibles sont plus drastiques pour les hauts niveaux de qualité audio que pour les niveaux de qualité audio inférieurs. Les Figures 23 à 25 illustrent les performances dans ce domaine du modèle B3 et des versions FftNnODG1 et CombNnODG3 du modèle pour les 84 éléments lors de la Phase 3.

FIGURE 23
B3: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG pour les 84 éléments lors de la Phase 3





FIGURE 24


FFTNnODG1: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG pour les 84 éléments lors de la Phase 3



1387-24

FIGURE 25

CombNnODG3: représentation de la moyenne des SDG, de l'intervalle de confiance et des ODG pour les 84 éléments lors de la Phase 3



1387-25

5 Sélection des versions optimales du modèle

Dix-huit versions différentes du modèle ont été évaluées sur le site des essais objectifs: 6 versions sont fondées sur la FFT, 6 versions utilisent un banc de filtres perceptuels adapté et 6 versions utilisent une combinaison de FFT et du banc de filtres. Le groupe FFT est destiné à être utilisé dans un système de mesure pouvant fonctionner en temps réel, les deux autres groupes nécessitent des calculs plus complexes et fourniront une meilleure précision. On peut diviser en deux sous-groupes les six versions du modèle de chaque groupe: un qui utilise les réseaux neuronaux et un qui ne les utilise pas. On intègre également pour comparaison les performances du modèle de référence d'avril 1996 (B3) pour la base de données 3.

5.1 Critères de présélection fondés sur la corrélation

- On a évalué les performances des 18 versions du modèle et du modèle de référence B3 avec deux ensembles de données qui n'étaient pas utilisés majoritairement pour l'apprentissage des modèles (la Phase 1, la deuxième partie de la Phase 3 et CRC n'ont pas été utilisées).
- La base de données 3 a été créée spécialement pour l'évaluation des modèles perceptuels. Environ la moitié de cette base de données a été utilisée pour l'apprentissage des modèles. On a utilisé la corrélation entre les résultats subjectifs et les résultats objectifs pour les éléments restants (DB3_2nd) pour évaluer les modèles objectifs.
- La base de données CRC a été créée par le CRC pour l'évaluation des schémas de codage sonores perceptuels. Cette base de données n'a pas été utilisée pour l'apprentissage des modèles perceptuels. La corrélation entre les résultats subjectifs et les résultats objectifs pour tous les éléments a été utilisée pour évaluer les modèles objectifs.

On trouvera dans les Tableaux 25 et 26 (corrélations et valeurs de l'erreur absolue) les résultats de la base de données 3.

Lors de la phase de présélection, on a pris en compte toutes les entrées permettant une quantification des performances de toutes les versions du modèle avec une pondération plus importante pour DB3. Sur la base de la comparaison globale, il fut décidé d'effectuer une nouvelle comparaison des deux versions du modèle de chaque groupe qui semblaient donner les meilleurs résultats. On trouvera dans le Tableau 25 la corrélation de ces six versions (trois fois 2 versions du modèle).

TABLEAU 25

Corrélation entre les SDG et les ODG

	FFTNnODG1	FFTNnODG2	FiltODG2	FiltODG3	CombNnODG3	CombODG3	B3
DB3_2nd	0,671	0,728	0,738	0,751	0,828	0,826	0,710
CRC	0,837	0,779	0,862	0,839	0,851	0,777	0,656

TABLEAU 26

Valeurs de l'erreur absolue

	FFTNnODG1	FFTNnODG2	FiltODG2	FiltODG3	CombNnODG3	CombODG3	B3
DB3_2nd	2,96	2,79	3,16	3,16	2,91	2,56	2,39
CRC	1,55	1,85	1,61	1,67	1,61	1,90	2,78

Les deux versions FFT du modèle ont des performances différentes avec les deux bases de données. Il fallait des critères supplémentaires pour choisir une des deux versions. En prenant en compte le fait que la base de données CRC était totalement inconnue, FFTNnODG1 semble avoir de meilleures performances.

Les versions combinées du modèle donnent de meilleurs résultats avec les deux bases de données par rapport aux versions FFT. Mais, les résultats sont moins bons avec la base de données CRC par rapport aux versions banc de filtres. On peut dire que les versions banc de filtres sont un cas particulier des versions combinées où la pondération des variables de sortie de la version FFT est zéro. On a donc préféré les versions combinées du modèle.

5.2 Analyse du nombre d'éléments non conformes

L'intervalle de 95% autour de la moyenne sur de nombreux auditeurs exprime la précision des données subjectives provenant des tests d'écoute. On a également évalué les performances des versions du modèle en prenant en compte les éléments non conformes. On définit un élément comme non conforme si la différence entre les données subjectives et les données objectives est supérieure à deux fois l'intervalle de confiance.

On trouvera dans le Tableau 27 le nombre d'éléments non conformes pour les six versions du modèle avec DB3. Sensible signifie qu'une version du modèle indique une qualité sonore inférieure à celle indiquée par l'évaluation subjective, insensible signifie l'inverse.

TABLEAU 27

Eléments non conformes

	FFTNnODG1	FFTNnODG2	FiltODG2	FiltODG3	CombNnODG3	CombODG3
Sensible	10	4	4	4	3	5
Insensible	13	13	11	13	12	14
Total	23	17	15	17	15	19

Si l'on considère le nombre d'éléments non conformes, la version FFTNnODG2 semble donner de meilleurs résultats que la version FFTNnODG1. La version CombNnODG3 donne les meilleurs résultats parmi les versions les plus précises.

5.3 Analyse de la gravité des non-conformités

TABLEAU 28

Eléments présentant des déviations de plus de 1,0 graduation entre les prédictions et les SDG

Nombre d'éléments non conformes	14	4	4	12	12	9	6
Version du modèle	B3	CombODG3	CombNnODG3	FftNnODG1	FftNnODG2	FiltODG2	FiltODG3
élément	jcodsmg	jcodsmg	jcodsmg	jcodsmg	jcodsmg	jcodsmg	jcodsmg
	qcodket	qcodket	pcodsmg	qcodket	qcodket	rcodpip	rcodpip
	pcodsmg	pcodsmg	ccodclv	pcodsmg	pcodsmg	qcodket	qcodket
	pcodcla	icodmar	acodclv	ocodsfe	pcodcla	pcodsmg	pcodsmg
	ocodclv			ncodcas	ocodsfe	ocodsax	ocodsax
	ncodcas			mcodcla	ncodglo	kcodpip	fcodsb2
	mcodpip			jcodveg	kcodcas	jcodveg	
	jcodyrc			jcodyrc	jcodveg	fcodsb2	
	icodtam			icodtam	jcodyrc	fcodcl2	
	icodsmg			icodmar	icodtam		
	fcodsb2			fcodcl2	ecodhrp		
	ecodhrp			ecodhrp	ccodclv		
	ccodclv						
	acodclv						

TABLEAU 29

**Éléments présentant des déviations de plus de 1,5 graduation
entre les prédictions et les SDG**

Nombre d'éléments non conformes	8	2	2	3	2	2	2
Version du modèle	B3	CombODG3	CombNnODG3	FftNnODG1	FftNnODG2	FiltODG2	<u>FiltODG3</u>
élément		jcodsmg	jcodsmg	jcodsmg	jcodsmg	jcodsmg	jcodsmg
	qcodket		pcodsmg				
	pcodsmg	pcodsmg		pcodsmg	pcodsmg		
						pcodsmg	pcodsmg
				ncodcas			
	ncodcas						
	jcodyc						
	icodtam						
	icodsmg						
	ccodclv						
	acodclv						

6 Conclusion

Suite aux décisions prises lors du développement, deux versions du modèle, sur les dix-huit versions proposées, ont été choisies pour satisfaire aux exigences des applications définies pour les méthodes de mesure objective. Une version simple, destinée à des réalisations en temps réel à moindre coût, et une version plus précise, qui ne fonctionne pas nécessairement en temps réel, ont été définies. Pour le processus de sélection, les critères définis ci-dessus ont été appliqués et analysés.

Pour la version en temps réel, on a choisi un modèle FFT, dénommé «FFTnNODG1», pour les raisons suivantes:

Aucune des versions FFT ne présentait un avantage significatif par rapport aux autres sur un quelconque des critères ci-dessus. En ce qui concerne les coefficients de corrélation entre les ODG et les SDG, et le nombre et la gravité des non conformités, chacune des versions évaluées a ses avantages et ses inconvénients. Néanmoins, il faut noter que «FFTnNODG1» propose la meilleure corrélation avec la base de données CRC'97 qui était totalement inconnue (0,837).

Pour la version de plus grande précision, on a préféré la version combinée, qui intègre une FFT et un banc de filtres, parce que cette approche intègre également le sous-ensemble d'un modèle purement banc de filtres et devrait donc avoir de meilleurs résultats. Six versions différentes d'un modèle combiné ont été évaluées lors du processus de sélection. La version choisie, «CombNnODG3», présente moins de non conformités et une meilleure corrélation ($r=0,851$ avec CRC'97) que les autres versions. La corrélation de cette version pour la totalité de la base de données 3 avait le même ordre de grandeur qu'une des versions «CombODG3», mais avait une meilleure corrélation que les autres versions.

APPENDICE 2 de L'ANNEXE 2

Description des bases de données de référence

1 Introduction

Lors du développement de la méthode de mesure objective de la qualité du son perçu, on a utilisé un certain nombre de bases de données pour l'apprentissage et la validation.

Certaines des bases de données contenaient des données casque et haut-parleur mélangées et, certaines uniquement des données casque. Pour les bases de données ayant des ensembles distincts de données casque et de données haut-parleur, on n'a utilisé que les données casque.

Un élément est un fragment sonore utilisé pour une évaluation subjective. Une condition est une dégradation unique. Tous les éléments ont été utilisés pour toutes les conditions expérimentales sauf pour les études avec DB2 et DB3. DB3 a été utilisée en partie pour l'apprentissage et en partie pour la validation (52 des 84 éléments ont été utilisés pour l'apprentissage lors de la deuxième phase de validation).

Apprentissage

- MPEG90
 - La moyenne des SDG par élément couvrait uniformément une gamme de 0,0 à -4,0.
 - Référence: ISO/IEC/JTC1/SC2/WG 11 MPEG/Audio test report, Document MPEG90/N0030, octobre 1990.
- MPEG91
 - Au moins 88% de la moyenne des SDG par élément étaient supérieurs à -2,0, et la gamme s'étendait de 0,1 à -3,8.
 - Référence: ISO/IEC/JTC1/SC2/WG 11 MPEG/Audio test report, Document MPEG91/N0010, juin 1991.
- ITU92DI
 - 80% de la moyenne des SDG par élément étaient supérieurs à -2,0, et la gamme s'étendait de 0,1 à -3,4.
 - Référence: voir aussi la Rec. UIT-R BS.1115.
- ITU92CO
 - Au moins 96% de la moyenne des SDG par élément étaient supérieurs à -2,0, et la gamme s'étendait de 0,2 à -2,4.
 - Référence: voir aussi la Rec. UIT-R BS.1115.
- ITU93
 - La plupart de la moyenne des SDG par élément étaient supérieurs à -2,0, et la gamme s'étendait de -0,1 à -2,3. Il n'y avait pas de différence significative entre les données de ces deux laboratoires.
 - Références: [Grusec et autres, 1997]; voir également la Rec. UIT-R BS.1115.
- MPEG95
 - Au moins 63% de la moyenne des SDG par élément étaient supérieurs à -2,0, et la gamme s'étendait de -0,2 à -3,8.
 - Référence: [Meares et Kim, 1995].
- EIA95cc
 - Au moins 93% de la moyenne des SDG par élément étaient supérieurs à -2,0, et la gamme s'étendait de 0,1 à -3,7.
 - Référence: [Grusec et autres, 1997].
- DB2
 - Les éléments n'ont pas tous été utilisés dans toutes les conditions.

Validation

- DB3
 - Les éléments n'ont pas tous été utilisés dans toutes les conditions.
- CRC97
 - La moyenne des SDG par élément couvrait uniformément une gamme de 0,1 à -3,6.
 - Référence: [Soulodre et autres, 1998].

Les paragraphes qui suivent décrivent les éléments intégrés aux différentes bases de données et les conditions appliquées.

2 Eléments par base de données

Item	MPEG90	MPEG91	ITU92DI	ITU92CO	ITU93	MPEG95	EIA95	DB2	DB3	CRC97
Accordion/Triangel		*								
Åsa Jinder			*	*	*					
Bag Pipe						*		*	*	
Bag Pipe-2								*		
Bass Clarinet								*		
Bass Guitar	*		*	*						
Bass Synth	*									
Carmen		*								
Castanets	*		*	*	*	*		*	*	
Clarnet					*		*	*	*	*
Clarinet-mono								*		
Clarnet2								*		
Claves									*	
Dalarnas Spelmansförbund "Trettondagsmarschen"			*	*						
Dire Straits "Ride Across the River"			*				*			*
Double Bass										*
Drum								*		
Fireworks	*									
Flute									*	
George Duke		*								
Glockenspiel	*	*				*	*	*	*	
Harpiscord			*	*	*	*	*	*	*	*
Horn								*		
Kettle drums									*	
Marimba								*	*	
MPE mono = Speech male engl. mono								*		
Music and rain							*			*
Muted trumpet							*			
Ornette Coleman	*	*	*	*						
Pearl Jam							*			
Percussion		*						*		
Piano Schubert									*	
Pitch Pipe						*			*	*
Ravel "Feria"			*							
Ry Cooder								*	*	
Ry Cooder (mono)									*	
Saxophon									*	
Snare drum									*	
Soprano Mozart									*	
Speech female engl						*			*	
Speech female germ									*	
Speech male engl	*	*							*	
Speech male germ			*	*	*				*	
Stravinsky "Wind Octet"			*	*						
Strings								*	*	
Strings mono								*		
Suzanne Vega "Toms Diner"	*	*	*	*				*	*	*
Suzanne Vega with breaking glass							*			
Tambourine		*						*	*	
Tracy Chapman	*									
Triangle			*	*				*	*	
Trumpet								*	*	*
Trumpet (Haydn)	*									
Tuba								*	*	
De sålde sina hemman (violin solo)					*					
Water Sound							*			
Wind Ensemble								*		
Xylophone									*	

3 Conditions expérimentales

Pour tous les débits binaires comportant l'indication kbit/s stéréo, on donne le débit binaire total, ex. 256 kbit/s stéréo signifie que 256 kbit/s sont alloués au total pour les deux canaux d'un signal stéréo. Si rien d'autre n'est indiqué, stéréo renvoie à un codage indépendant par canal.

3.1 MPEG90

Trois débits binaires: 64 kbit/s mono, 192 kbit/s et 256 kbit/s stéréo, les matériaux n'étaient pas tous disponibles pour cette base de données.

- Musicam.
- SB-ADPCM.

3.2 MPEG91

Trois débits binaires: 64 kbit/s mono, 192 kbit/s, et 256 kbit/s stéréo.

- MPEG1 Layer I.
- MPEG1 Layer II.
- MPEG1 Layer III.
- MUSICAM.
- ASPEC.
- NICAM.

3.3 ITU92DI

Cinq codecs de distribution: 240 kbits/s stéréo.

Chaque élément a été traité par le même codec trois fois en tandem, avec une perte en niveau de 0,1 dB avant chaque passe.

- MPEG1 Layer II.
- MPEG1 Layer III.
- Dolby AC-2.
- Aware.
- NHK.

3.4 ITU92CO

Six codecs de contribution: 360 kbits/s stereo. Chaque élément a été traité par le même codec trois fois en tandem, avec une perte en niveau de 0,1 dB avant chaque passe.

- MPEG1 Layer II.
- MPEG1 Layer III.
- Dolby AC-2.
- Dolby Low-Delay.
- Aware.

3.5 ITU93

Configurations codec tandem MPEG1 Layer II:

- Codec Emission uniquement à 256 kbit/s stéréo.
- Codec Emission uniquement à 192 kbit/s stéréo (codage stéréo commun).
- Huit codecs de contribution à 360 kbit/s suivis d'un codec d'émission à 256 kbit/s, tous stéréo.
- Huit codecs de contribution à 360 kbit/s suivis d'un codec d'émission à 192 kbit/s, tous stéréo.
- Cinq codecs de contribution à 360 kbit/s suivis de trois codecs de distribution à 240 kbit/s et un codec d'émission à 256 kbit/s, tous stéréo.
- Cinq codecs de contribution à 360 kbit/s suivis de trois codecs de distribution à 240 kbit/s et un codec d'émission à 192 kbit/s, tous stéréo.

3.6 MPEG95

Réalisations codec (64 kbits/s):

- Vingt-deux variations d'encodage ont été choisies dans un ensemble plus important de méthodes d'encodage disponible dans 6 codecs pour réaliser un sous-ensemble de 4 modèles temps/fréquence basse résolution et 17 modèles temps/fréquence haute résolution.
- Les organisations participantes étaient AT&T, Fraunhofer, Sony, GCL, RAI/Alcatel, et Philips.
- Tous les éléments étaient des enregistrements mono présentés sur deux canaux.

3.7 EIA95

- | | |
|--------------------------------|--|
| - Eureka 147/MPEG1 Layer II #1 | 224 kbit/s stéréo (codage stéréo commun) |
| - Eureka 147/MPEG1 Layer II #2 | 192 kbit/s stéréo (codage stéréo commun) |
| - AT&T/Lucent | 160 kbit/s stéréo |
| - AT&T/Lucent/Amati #1 | 128 kbit/s stéréo |
| - AT&T/Lucent/Amati #2 | 160 kbit/s stéréo |
| - VOA/JPL | 160 kbit/s stéréo |
| - USADR-FM #1 | 128-256 kbit/s stéréo (débit binaire variable) |
| - USADR-FM #2 | 128-256 kbit/s stéréo (débit binaire variable) |
| - USADR-AM | 96 kbit/s stéréo |

3.8 DB2

- | | |
|--|---|
| - MPEG1 Layer II, | 256 kbit/s stéréo, 1, 3, 5, 7, et 9 étages. |
| - Dolby AC2, | 256 kbit/s stéréo, 1, 3, 5, 7, et 9 étages. |
| - MPEG1 Layer II, | 192 kbit/s stéréo (codage stéréo commun). |
| - MPEG1 Layer II, | 64 kbit/s mono. |
| - MPEG2 Layer II, | 64 kbit/s mono. |
| - MPEG1 Layer II, | 384 kbit/s stéréo. |
| - MPEG1 Layer III, | 128, 160, 192 kbit/s, tous stéréo. |
| - APT-X, | 256 et 384 kbit/s les deux stéréo. |
| - Quantification distorsion | |
| - Enregistrement analogique 1, 2, 3 étages | |
| - Ecrêtage | |

3.9 DB3

- | | |
|-------------------------------------|--|
| - NICAM | |
| - MiniDisc and MiniDisc + Layer II, | 192 kbit/s, stéréo (codage stéréo commun) |
| - Dolby AC2, | 256 kbit/s stéréo, 1, 3, 5, 7, et 9 étages |
| - MPEG1 Layer II, | sélection de la base de données Swisscom, >192 kbit/s stéréo |
| - MPEG1 Layer III, | 128 et 160 kbit/s les deux stéréo (codage stéréo commun) |
| - MPEG AAC, | 128 kbit/s stéréo (codage stéréo commun) |
| - MPEG Layer III, | 128 + Layer II, 384 + Layer II, 224 kbit/s, tous stéréo |
| - Dolby AC3, | 256 kbit/s stéréo |
| - Dolby AC3, | 256 + MPEG Layer II, 224 kbit/s, les deux stéréo |
| - Quantification distorsion | |
| - THD | |
| - Bruit | |

3.10 CRC97

- AT&T PAC	64, 96, 128, et 160 kbit/s, tous stéréo
- Dolby AC3	128, 160, et 192 kbit/s, tous stéréo
- MPEG1 Layer II software	128, 160, et 192 kbit/s, tous stéréo
- MPEG1 Layer II hardware (ITIS)	96, 128, 160, 192 kbit/s, tous stéréo
- MPEG4 AAC	96 et 128 kbit/s, les deux stéréo
- MPEG1 Layer III	128 kbit/s stéréo

4 Éléments par condition pour DB2 et DB3

4.1 DB2

		Condition N°	Éléments
Site test I, NHK Japon			
Layer II, 256 kbit/s	1 étage	CO13	CLA,RYC,SB1,STR
	3 étages	CO11	CLA,RYC,SB1,STR
	5 étages	CO19	CLA,RYC,SB1,STR
	7 étages	CO18	CLA,RYC,SB1,STR
	9 étages	CO15	CLA,RYC,SB1,STR
NBC (Dolby AC2)	1 étage	CO1A	CAS,RYC,STR,WIN
	3 étages	CO12	CAS,RYC,STR,WIN
	5 étages	CO17	CAS,RYC,STR,WIN
	7 étages	CO16	CAS,RYC,STR,WIN
	9 étages	CO14	CAS,RYC,STR,WIN
Site test II, DR Danemark			
Layer II, 256 kbit/s	1 étage	CO2B	CLA,RYC,SB1,STR
Layer II, 192 kbit/s js		CO25	CLA,RYC,SB1,STR
Layer II, 64 kbit/s mono		CO27	MLA,MPE,MTR,MYC
NBC (Dolby AC2)	5 étages	CO29	CAS,RYC,STR,WIN
MPEG2/L2 LSF		CO22	MLA,MPE,MTR,MYC
Analogique 1		CO23	PER
Analogique 2		CO2A	PER
Analogique 3		CO28	PER
Erreurs 1		CO24	GLO,HRN,TRI
Erreurs 2		CO21	GLO,HRN,TRI
Ecrêtage		CO26	BAS,CL2,TUB
Site test III, NRK Norvège			
Layer II, 384 kbit/s		CO34	CLA,RYC,SB1,STR
Layer II, 256 kbit/s	1 étage	CO31	CLA,RYC,SB1,STR
NBC (Dolby AC2)	5 étages	CO3B	CAS,RYC,STR,WIN
Layer III (ASPEC3), 192 kbit/s		CO32	CLA,STR,TAM,VEG
Layer III ASPEC3), 128 kbit/s		CO39	CLA,STR,TAM,VEG
Layer III ASPEC3), 160 kbit/s		CO3A	CLA,STR,TAM,VEG
APT-X, 256 kbit/s		CO33	HAR,SB2,STR,TPT
APT-X, 384 kbit/s		CO36	HAR,SB2,STR,TPT
Quantification dist. 1		CO35	DRU
Quantification dist. 2		CO37	DRU
Quantification dist. 3		CO38	DRU

Eléments de tests

STR	Musique populaire suédoise, enregistrement SR, utilisé auparavant
SB1	Cornemuses, enregistrement SR
SB2	Cornemuses, enregistrement SR
CLA	Clarinette, SQUAM 16/2
TAM	Tambourin, enregistrement SR, utilisé auparavant
WIN	Stravinski, ensemble de vents, utilisé auparavant
TPT	Trompette, SQUAM 21/2
HAR	Ensemble Harlequin, enregistrement BBC G 49/17
VEG	Suzanne Vega, master ancien, utilisé auparavant
CAS	Castagnettes, SQUAM 27
SPE	Voix allemande, SQUAM 54
RYC	Ry Cooder, CD: JAZZ tr 11 (0,25 – 0,47)
PER	Percussion, Marimba Basse Japonaise, CD: Sony/CBS 32DC 5027
HRN	Cor, SQUAM 23/2
GLO	Glockenspiel, SQUAM 35/1, utilisé auparavant
TRI	Triangle, SQUAM 32/2
DRU	Tambours, SQUAM 28
CL2	Clarinette, SQUAM 16/2
BAS	Clarinette Basse, SQUAM 17
TUB	Tuba, SQUAM 24
MPE	Mixage mono de SPE
MTR	Mixage mono de STR
MLA	Mixage mono de CLA
MYC	Mixage mono de RYC

Test/Elément	Clarinette	Clarinette mono	Ry Cooder	Ry Cooder mono	Cornemuses 1	Cordes	Cordes mono	Castagnettes	Ensemble vents	MPE mono	Tambourin	Suzanne Vega	Clavecin	Cornemuses 2	Trompette	Tambourin	Percussion	Glockenspiel	Cor	Triangle	BAS	Clarinette 2	Tuba	
MPEG1 Layer 2, 256 kbit/s, 1 étage	X		X		X	X																		
MPEG1 Layer 2, 256 kbit/s, 3 étages	X		X		X	X																		
MPEG1 Layer 2, 256 kbit/s, 5 étages	X		X		X	X																		
MPEG1 Layer 2, 256 kbit/s, 7 étages	X		X		X	X																		
MPEG1 Layer 2, 256 kbit/s, 9 étages	X		X		X	X																		
Dolby AC2, 256 kbit/s, 1 étage			X			X		X	X															
Dolby AC2, 256 kbit/s, 3 étages			X			X		X	X															
Dolby AC2, 256 kbit/s, 5 étages			X			X		X	X															
Dolby AC2, 256 kbit/s, 7 étages			X			X		X	X															
Dolby AC2, 256 kbit/s, 9 étages			X			X		X	X															
MPEG1 Layer 2, 192 kbit/s stéréo commu	X		X		X	X																		
MPEG1 Layer 2, 64 kbit/s mono		X		X			X			X														
MPEG2 Layer 2, 64 kbit/s mono		X		X			X			X														
MPEG1 Layer 2, 384 kbit/s	X		X		X	X																		
MPEG1 Layer 3 (ASPEC 3), 192 kbit/s	X					X					X	X												
MPEG1 Layer 3 (ASPEC 3), 128 kbit/s	X					X					X	X												
MPEG1 Layer 3 (ASPEC 3), 160 kbit/s	X					X					X	X												
APT-X, 256 kbit/s						X							X	X	X									
APT-X, 384 kbit/s						X							X	X	X									
Quantification distorsion 1																	X							
Quantification distorsion 2																	X							
Quantification distorsion 3																	X							
Enregistrement analogique 1 étage																		X						
Enregistrement analogique 2 étages																		X						
Enregistrement analogique 3 étages																		X						
Erreurs bit 1																		X	X	X				
Erreurs bit 2																		X	X	X				
Ecrêtage																						X	X	X

4.2 DB3

Élément/T	Nom	1	2MD	2MDL2	3.1Step	3.3Step	3.5Step	3.7Step	3.9Step	4	5	6 low	6 high	7	8	9	10	11	12	13		
																					1.) NICAM	
																						2.) MD and MD + L2 (192 kbit/s)
																						3.) AC2 (256 kbit/s). 1. 3. 5. 7.9
13(1) Flute	flu							X	X													4.) L2 (ST d-b. 3192 kbit/s)
16(2) Clarinette	cla				X		X			X	X			X	X							5.) Laver2 (256 kbit/s). 8 staoges
20(1) Saxophone	sax								X	X												6.) Laver3. 128 and 160
21(2) Trompette	tpt					X	X															7.) AAC. 128 kbit/s
24(2) Tuba	tub																		X			8.) L3 (128) + L2 (384) + L2
26(1) Claves	clv		X	X			X	X	X												X	9.) AC3 (256)
27 Castagnettes	cas									X			X		X	X					X	10.) AC3 (256) + L2 (224)
28 Caisse claire	sna	X																			X	11.) Quantification distorsion
30 Timbales	ket																			X		12.) THD
32(1/2) Triangle	tri		X	X	X	X				X											X	13.) Bruit
35(1/2) Glockenspiel	glo											X	X								X	
36(1) Xylophone	xyl																				X	
40(1) Clavecin	hrp				X	X					X				X							
49 Voix femme anglaise	sfe								X	X											X	
54 Voix homme allemand	smg	X	X	X	X	X	X			X												
60 Piano Schubert	pia																				X	X
61 Soprano Mozart	sop		X	X																		
53 Voix femme allemande	sfg																					
50 Voix homme anglais	sme												X	X								
Ref_tam	tam	X																			X	X
Ref_str	str																				X	X
Ref_har	har																					
Ry Cooder	ryc										X						X	X				
Susanne Vega	veg									X	X	X		X	X							
Diapason	pip											X	X	X	X							
Marimba	mar	X																				X
Cornemuse	sb1									X												
Nom		i	b	s	g	e	p	c	o	f	i	r	k	l	m	h	d	q	n	a		

Exemples Noms:		
Référence:	irefflu	
Test:	icodflu	

Glossaire

Valeur de l'erreur absolue (AES)

La valeur de l'erreur absolue est dérivée d'une formule développée spécialement pour l'évaluation de la qualité des résultats obtenus à partir d'une méthode de mesure perceptuelle objective. Il prend en compte les intervalles de confiance des valeurs moyennes des tests d'écoute subjective.

Qualité audio de base

La qualité audio de base est un attribut subjectif global qui intègre toutes les différences détectées entre le Signal de référence et sa version traitée.

Marge de codage

La marge de codage est un paramètre de la qualité qui mesure la distance entre les artefacts de codage inaudibles et le seuil où ces artefacts deviennent audibles.

Variables de sortie de modèle (MOV)

Les variables de sortie de modèle sont des valeurs de sortie intermédiaires de la méthode de mesure perceptuelle. Ces variables sont fondées sur les découvertes psychoacoustiques de base et peuvent donc servir à définir plus avant les artefacts de codage.

Note différentielle objective (ODG)

La note différentielle objective est le paramètre de sortie principal de la méthode de mesure perceptuelle. Elle correspond à la SDG et est le paramètre de mesure qui donne la qualité sonore de base globale. L'ODG est située entre 0 et -4.

Mesure Off-line

Procédure de mesure qui n'interfère pas avec la transmission d'un programme en cours.

Mesure en ligne

Procédure de mesure qui repose sur la transmission de programmes en cours, ou partie de cette transmission.

Note différentielle subjective (SDG)

Dans un test d'écoute conforme à la Recommandation UIT-R BS.1116 la qualité audio de base de la référence cachée et de la version traitée de la référence sont notées sur l'échelle de dégradation à cinq notes. La note différentielle est la note donnée au Signal testé moins la note donnée au Signal de référence. Idéalement, la SDG doit être située entre 0 et -4. Si la référence n'a pas été identifiée correctement, la SDG est positive.

Abréviations

ADB	Bloc distordu moyen
AES	Valeur de l'erreur absolue
ASD	Différence auditive spectrale
Avg	Moyenne (linéaire)
BAQ	Qualité audio de base
Bw	Largeur de bande
CI	Intervalle de confiance
CM	Marge de codage
DBn	Base de données (1, 2 ou 3)
DC	Courant direct
DFT	Transformation de Fourier discrète
DIX	Indice de perturbation
DUT	Système testé
EHS	Structure harmonique d'erreur
ERB	Largeur de bande rectangulaire équivalente
fac	facteur
FFT	Transformation de Fourier rapide
FIR	Réponse impulsionnelle finie
IIR	Réponse impulsionnelle infinie
ISO	Organisation internationale de normalisation
JNLD	Différence de niveau juste audible
MFPD	Probabilité de détection maximum filtrée
MOV	Variable de sortie de modèle
MPEG	Moving Picture Expert Group
NL	Intensité acoustique du bruit
NMR	Rapport bruit/masque
OASE	Evaluation objective du signal sonore
OCM	Marge de codage objective
ODG	Note différentielle objective
PAQM	Mesure perceptuelle de la qualité du son

PEAQ	Mesure objective de la qualité du son perçu
PERCEVAL	Evaluation perceptuelle
POM	Mesure perceptuelle objective
REF	Signal de référence
res	Résolution
r.m.s.	Moyenne quadratique
ROEX	Exponentielle arrondie
ROV	Débit des valeurs de sortie
SCM	Marge de codage subjective
SDG	Note différentielle subjective
SNR	Rapport signal/bruit
SPL	Niveau de pression sonore
SUT	Signal testé
THD	Distorsion harmonique totale
Win	Moyenne avec fenêtrage

RÉFÉRENCES BIBLIOGRAPHIQUES

- Aures W., [septembre 1984] *Berechnungsverfahren für den Wohlklang beliebiger Schallsignale, ein Beitrag zur gehörbezogenen Schallanalyse*. Dissertation an der Fakultät für Elektrotechnik der Technischen Universität München.
- Beerends J.G. et Stermerdink J.A., [décembre 1992] *A perceptual audio quality measure based on a psychoacoustic sound representation*, J. Audio Eng. Soc., Vol. 40, pp 963-978.
- Beerends J.G., van den Brink W.A.C. et Rodger B., [mai 1996] *The role of informational masking and perceptual streaming in the measurement of music codec quality*, Contribution to the 100th AES Convention, Copenhagen, preprint 4176.
- Beerends J.G. et Stermerdink J.A., [février 1994] *Modeling a cognitive aspect in the measurement of the quality of music codecs*, Contribution to the 96th AES Convention, Amsterdam, preprint 3800.
- Beerends J.G. et Stermerdink J.A., [mars 1994] *A perceptual speech quality measure based on a psychoacoustic sound representation*, J. Audio Eng. Soc., Vol. 42, pp 115-123.
- Brandenburg K., [1987] *Evaluation of quality for audio encoding at low bit rates*, Contribution to the 82nd AES Convention, Londres 1987, preprint 2433.
- Bregman A.S., [1990] *Auditory scene analysis: The perceptual organisation of sound*, MIT Press, Cambridge MA.
- Cohen E. A. et Fielder L.D., [mai 1992] *Determining noise criteria for recording environments*, J. Audio Eng. Soc. Vol. 40, pp 384-402.
- Colomes C., Lever M., Rault J.B., et Dehery Y.F., [avril 1995] *A perceptual model applied to audio bit-rate reduction*, J. Audio Eng. Soc., Vol. 43, pp 233-240.
- Feiten B., [mars 1997] *Measuring the Coding Margin of Perceptual Codecs with the Difference Signal*. 102nd AES-Convention München, preprint 4417.
- Grusec, T., Thibault, L., et Soulodre, G. [septembre 1997] *EIA/NRSC DAR systems subjective tests. Part 1: Audio codec quality*, IEEE Transactions on Broadcasting, Vol. 43, N° 3.
- Karjalainen J., [mars 1985] *A new auditory model for the evaluation of sound quality of audio system*, Proceedings of the ICASSP, Tampa, Florida, pp 608-611.

- Leek M.R. et Watson C.S., [1984] *Learning to detect auditory pattern components*, J. Acoust. Soc. Am. Vol. 76, pp 1037-1044.
- Meares, D.J., Kim, S-W, [juillet 1995] «NBC time/frequency module subjective tests: overall results», ISO/IEC JTC1/SC29/WG11 N0973 MPEG95/208.
- Moore B.C., [1986] *Frequency Selectivity in Hearing*, Academic Press, Londres.
- Moore B.C., [1989] *An introduction to the psychology of hearing*, Academic Press, Londres.
- Paillard B., Mabillean P., Morissette S., et Soumagne J., [1992] Perceval: *Perceptual evaluation of the quality of audio signals*, J. Audio Eng. Soc., Vol. 40, pp 21-31.
- Schroeder M.R., Atal B.S. et Hall J.L., [décembre 1979] *Optimizing digital speech coders by exploiting masking properties of the human ear*, J. Acoust. Soc. Am., Vol. 66, pp 1647-1652.
- Soulodre, G., Grusec, T., Lavoie, M., et Thibault, L. [mars 1998] *Subjective evaluation of state-of-the-art 2-channel audio codecs*, Journal of the Audio Engineering Society.
- Sporer T., [octobre 1997] *Objective audio signal evaluation -- applied psychoacoustics for modeling the perceived quality of digital audio*, 103rd AES-Convention, New York, preprint 4512.
- Terhardt E., [1979] *Calculating Virtual Pitch*, *Hearing Research*, Vol. 1, pp 155-182.
- Thiede T. et Kabot E., [1996] *A New Perceptual Quality Measure for Bit Rate Reduced Audio*, Contribution to the 100th AES Convention, Copenhagen preprint 4280.
- Treurniet, W.C. [1996] *Simulation of individual listeners with an auditory model*. Proceedings of the Audio Engineering Society, Copenhagen, Denmark, Reprint Number 4154.
- von Bismarck G., [1974] *Sharpness as an attribute of the timbre of steady sounds*. *Acustica* 30, pp 159-172.
- Zwicker E. et Fastl H., [1990] *Psychoacoustics, Facts and Models*. Berlin; Heidelberg: Springer Verlag.
- Zwicker E. et Feldtkeller R., [1967] *Das Ohr als Nachrichtenempfänger*. Stuttgart: Hirzel Verlag.

Bibliographie

- Grusec, T., Thibault, L., et Soulodre, G. [1995] *Subjective evaluation of high quality audio coding systems: methods and results in the two-channel case*, preprint 4065 (F-5), Proceedings of the AES, New York.
-