

RECOMMANDATION UIT-R BS.1116-1*

MÉTHODES D'ÉVALUATION SUBJECTIVE DES DÉGRADATIONS FAIBLES DANS LES SYSTÈMES AUDIO Y COMPRIS LES SYSTÈMES SONORES MULTIVOIES

(Question UIT-R 85/10)

(1994-1997)

L'Assemblée des radiocommunications de l'UIT,

considérant

- a) que les Recommandations UIT-R BT.500, UIT-R BS.562, UIT-R BT.710 et UIT-R BT.811 ont défini des méthodes d'évaluation subjective de la qualité des systèmes audio et vidéo;
- b) que les essais d'écoute subjectifs permettent d'évaluer le degré de gêne qu'inflige à l'auditeur toute dégradation que subit le signal utile au cours de sa transmission de son origine jusqu'à l'auditeur;
- c) que les méthodes objectives classiques ne conviennent pas forcément pour évaluer les schémas de codage audio perfectionnés et que l'on élabore actuellement des méthodes d'évaluation objectives perceptuelles pour vérifier la qualité de son des systèmes sonores;
- d) qu'il est important d'utiliser des méthodes normalisées pour l'échange, la compatibilité et l'évaluation correcte des résultats des essais;
- e) que la mise en place de nouveaux systèmes audio numériques perfectionnés qui tirent parti des propriétés psychoacoustiques exige, notamment dans le cas des dégradations faibles, que les méthodes d'évaluation subjective progressent;
- f) que la mise en place de nouveaux systèmes à son stéréophonique avec ou sans image associée exige de nouvelles méthodes d'évaluation subjective y compris les conditions expérimentales,

recommande

- 1** que les procédures d'essai, d'évaluation et de présentation que décrit l'Annexe 1 servent à l'évaluation subjective des dégradations faibles des systèmes audio, y compris les systèmes sonores multivoies (avec ou sans image).

ANNEXE 1

1 Généralités**1.1 Domaine d'application**

La présente Recommandation est destinée à être utilisée pour évaluer des systèmes qui introduisent des dégradations si infimes qu'elles ne sont pas décelables sans contrôle rigoureux des conditions d'expérimentation et sans analyse statistique appropriée. Si elle était appliquée à des systèmes qui introduisent des dégradations relativement importantes et aisément décelables, elle entraînerait une dépense excessive de temps et d'effort et pourrait donner des résultats moins fiables que ceux obtenus avec un essai plus simple. La présente Recommandation constitue la référence de base pour d'autres Recommandations, qui, elles, peuvent introduire des conditions particulières supplémentaires ou des spécifications plus souples que celles définies dans la présente Annexe.

* Cette Recommandation doit être portée à l'attention du Groupe ad hoc audio ISO/MPEG (Organisation internationale de normalisation/ Moving Picture Experts Group).

1.2 Table des matières

La présente Annexe comprend 11 parties qui indiquent en détail les conditions applicables aux divers aspects des essais:

- 1 Généralités
- 2 Conception des expériences
- 3 Choix des groupes d'auditeurs
- 4 Méthode d'essai
- 5 Caractéristiques
- 6 Eléments de programme
- 7 Dispositifs de reproduction
- 8 Conditions d'écoute
- 9 Analyse statistique
- 10 Présentation des résultats des analyses statistiques
- 11 Contenu des rapports d'essai.

Par ailleurs, des directives concernant le choix des auditeurs experts figurent dans des Appendices qui contiennent en outre un exemple des consignes données aux participants.

Un certain nombre de mots d'usage courant sont utilisés ici dans un sens technique. On trouvera un glossaire de ces termes dans l'Appendice 4.

2 Conception des expériences

Si l'on veut rassembler des informations fiables dans un domaine d'intérêt scientifique, on dispose d'un grand nombre de stratégies de recherche différentes. Pour l'évaluation subjective des dégradations faibles dans les systèmes audio, il faut recourir aux méthodes expérimentales les plus strictes. Les expériences subjectives se caractérisent tout d'abord par une maîtrise réelle des conditions expérimentales et ensuite par les données quantitatives fournies par des observateurs humains.

Il faut définir et organiser avec soin les expériences pour assurer qu'aucun facteur non contrôlé n'affecte les essais d'écoute, ce qui créerait des ambiguïtés. Si, par exemple, la séquence d'éléments sonores utilisée est la même pour tous les participants à un essai d'écoute, on ne peut avoir la certitude que les jugements qu'ils ont portés ne tiennent pas davantage à la séquence qu'aux divers niveaux de dégradation présentés. Il faut donc que les conditions d'essai soient telles qu'elles ne fassent apparaître que les effets des facteurs indépendants.

Au cas où il serait probable que les dégradations éventuelles et d'autres caractéristiques soient distribuées de façon homogène tout au long de l'essai d'écoute, il faudrait que la présentation des conditions d'essai soit rendue tout à fait aléatoire.

S'il peut y avoir non-homogénéité, il faudra en tenir compte dans la façon de présenter les conditions d'essai. Par exemple, si les éléments à évaluer sont de difficulté variable, il faudra présenter les stimulus dans un ordre aléatoire, au cours d'une séance ou d'une séance à l'autre.

De même, on organisera les essais d'écoute de façon que les participants ne soient pas fatigués au point que leurs appréciations soient moins précises. Sauf si la correspondance entre son et image est importante, il est préférable que l'évaluation des systèmes audio s'effectue sans les images associées.

Il est très important d'inclure des contrôles appropriés. Il s'agit généralement d'insérer des éléments audio non dégradés sans que les participants puissent les déceler. Les différences entre l'appréciation de ces stimulus de contrôle et de ceux qui peuvent être dégradés permettent de conclure que les notes sont bien des évaluations des dégradations.

On reviendra par la suite sur ces considérations. Il ne faut pas oublier que la conception et la réalisation des expériences mais aussi l'analyse statistique sont des questions complexes et qu'une Recommandation comme celle-ci ne saurait donner que des directives très générales. Il est recommandé de faire appel à des spécialistes de la conception des expériences et des statistiques avant de commencer à organiser des essais d'écoute.

3 Choix des groupes d'auditeurs

3.1 Auditeurs experts

Il est essentiel que les données issues des essais d'écoute servant à évaluer les dégradations faibles dans les systèmes audio proviennent exclusivement de participants ayant reçu une formation pour détecter de tels défauts. La présence d'auditeurs experts est d'autant plus nécessaire que la qualité des systèmes étudiés est élevée.

3.2 Critères de choix des participants

Le résultat des essais subjectifs effectués avec des groupes d'auditeurs sélectionnés qui jugent des systèmes audio présentant de faibles dégradations ne se prête pas avant tout à une extrapolation au public en général. L'objectif visé consiste en principe à rechercher si un groupe d'auditeurs experts est capable, dans certaines conditions, de déceler des dégradations relativement subtiles et à fournir aussi une estimation quantitative des dégradations introduites. Cette procédure d'essai doit être très élaborée de façon à mettre en évidence les problèmes susceptibles de se poser à long terme dans les diverses conditions qui apparaissent en réalité dès lors qu'un système a été proposé à l'usager.

Il faut parfois introduire une technique de rejet avant ou après l'essai réel (pré ou postsélection) ou encore recourir à l'une et à l'autre. L'élimination consiste ici en un processus où l'on néglige tous les jugements portés par tel ou tel participant.

Tout type de technique de rejet qui ne serait ni analysé ni mis en œuvre avec soin risque de fausser les résultats. Lorsque des données ont été éliminées, il est donc très important que le rapport relatif à l'essai décrive clairement le critère utilisé afin que le lecteur puisse se forger sa propre opinion.

3.2.1 Présélection des participants

Les procédures de présélection reposent sur des méthodes telles que les essais audiométriques, le choix des participants en fonction de leur expérience acquise et de leur compétence lors d'essais précédents, et l'élimination de certains d'eux d'après l'analyse statistique des essais préliminaires. La présélection peut aussi se fonder sur la procédure de formation.

La principale raison en faveur de l'introduction d'une technique de présélection est le souci d'avoir des essais d'écoute efficaces, encore qu'il faille tenir compte du risque d'une limitation trop importante de la validité des résultats.

3.2.2 Postsélection des participants

On peut, dans l'ensemble, distinguer au moins deux catégories de méthodes de postsélection; l'une est fondée sur les incohérences par rapport au résultat moyen, l'autre sur la faculté du participant d'effectuer les identifications correctes. La première n'est jamais légitime. Quand un essai d'écoute subjectif est effectué avec la méthode d'essai recommandée ici, l'information nécessaire à la seconde méthode de postsélection est automatiquement disponible. L'Appendice 1 décrit une méthode statistique suggérée à cet effet.

Les méthodes servent essentiellement à éliminer les participants qui ne peuvent faire les distinctions appropriées. L'application d'une méthode de postsélection peut aider à dégager les tendances dans les résultats d'essai. Il faut toutefois être prudent en raison des différences de sensibilité des participants aux divers défauts.

3.3 Effectif d'un groupe d'écoute

On peut prévoir l'effectif approprié d'un groupe d'écoute à condition de pouvoir estimer la variance et de connaître la résolution requise de l'expérience.

Lorsque les conditions d'un essai d'écoute sont bien maîtrisées tant du point de vue technique que psychologique, l'expérience a montré que les données fournies par 20 participants suffisent souvent pour tirer de l'essai des conclusions appropriées. Si l'analyse est effectuée au fur et à mesure des essais, il n'est pas nécessaire de tenir compte d'un nombre plus important de participants dès que l'on a obtenu un degré de précision statistique suffisant pour tirer les conclusions appropriées.

Si l'on prévoit que certains des systèmes à l'essai seront quasiment transparents, il faudra retenir un plus grand nombre de participants pour avoir la certitude qu'ils seront assez nombreux à passer avec succès le test de postsélection.

Si, pour une raison quelconque, on ne maîtrise pas bien les conditions de l'expérience, il faudra davantage de participants pour arriver à la résolution voulue.

L'effectif du groupe d'écoute ne dépend pas uniquement de la résolution désirée. Le résultat des expériences du type considéré dans la présente Recommandation n'est, en pratique, valable que pour le groupe d'auditeurs experts ayant participé à l'essai. En augmentant l'effectif du groupe, on peut donc estimer que le résultat serait valable pour un groupe plus général d'auditeurs experts et serait alors jugé plus convaincant. On peut aussi avoir besoin d'augmenter l'effectif pour qu'il y ait plus de chances que la sensibilité des divers participants aux différents défauts varie.

4 Méthode d'essai

Pour effectuer des évaluations subjectives dans le cas de systèmes qui présentent de faibles dégradations, il faut choisir une méthode appropriée. On estime que la méthode de «doublement aveugle à triple stimulus et référence dissimulée» est particulièrement sensible, stable et permet de détecter avec précision les faibles dégradations. Il faudra donc l'utiliser pour ce type d'essai.

Sous la forme préférée et la plus sensible de cette méthode, il n'y a qu'un participant à la fois et il est libre de choisir un stimulus parmi trois («A», «B», «C»). La référence connue est toujours présente comme stimulus «A». La référence dissimulée et l'objet de l'essai sont disponibles simultanément mais sont attribués au hasard des essais aux stimulus «B» et «C».

Le participant est prié d'évaluer la dégradation de «B» comparé à «A» et de «C» comparé à «A» selon l'échelle continue de dégradation à 5 notes. L'un des stimulus, «B» ou «C», ne devrait pas se distinguer du stimulus «A»; l'autre peut présenter une dégradation. Toute différence décelée entre la référence et les autres stimulus doit être interprétée comme une dégradation.

Dans cette méthode préférée, dès que le participant a fini de noter l'essai, il doit être possible de passer à l'essai suivant. On peut répéter l'extrait jusqu'à ce que le participant ait fourni son évaluation. C'est donc lui qui définit le rythme de la procédure d'essai.

L'échelle d'évaluation sera traitée de façon continue compte tenu des «repères» de l'échelle de dégradation à 5 notes (voir le Tableau 1) tirée de la Recommandation UIT-R BS.1284.

TABLEAU 1

Dégradation	Note
Imperceptible	5,0
Perceptible mais non gênant	4,0
Légèrement gênant	3,0
Gênant	2,0
Très gênant	1,0

NOTE 1 – On a montré que l'utilisation de points de repère intermédiaires prédéfinis pouvait introduire des distorsions [Poulton, 1992]. Il est possible d'utiliser l'échelle de chiffres sans la description des points de repère; dans ce cas, l'orientation voulue de l'échelle doit être indiquée. Cette façon de procéder peut permettre de surmonter les problèmes de traduction rencontrés lors de la comparaison d'essais effectués dans des langues différentes.

Si on n'utilise pas des points de repère intermédiaires, il est indispensable que les résultats de chaque participant soient normalisés par rapport à un écart moyen type. On peut appliquer l'équation suivante pour normaliser les résultats tout en conservant l'échelle initiale:

$$Z_i = \frac{(x_i - x_{si})}{s_{si}} \cdot s_s + x_s$$

où:

- Z_i : résultat normalisé
- x_i : note donnée par le résultat du participant i
- x_{si} : note moyenne du participant i pendant la séance s
- x_s : note moyenne de tous les participants pendant la séance s
- s_s : écart type pour tous les participants pendant la séance s
- s_{si} : écart type pour le participant i pendant la séance s .

L'utilisation d'échelles sans points de repère intermédiaires empêche également toute interprétation des résultats en termes absolus.

Il est recommandé d'utiliser cette échelle avec une précision de la première décimale.

La méthode d'essai comprend deux parties: la phase de familiarisation ou d'entraînement et la phase de notation.

4.1 Phase de familiarisation ou d'entraînement

Avant de passer à la notation proprement dite, il faut laisser aux participants le temps de bien se familiariser avec le dispositif d'essai, l'environnement, la méthode et les échelles de notation et leur utilisation. Ils doivent aussi avoir une bonne connaissance des défauts à étudier. Pour les essais les plus délicats, il faut leur présenter auparavant tous les extraits qu'ils auront à noter pendant les séances suivantes consacrées à la notation. Au cours de la familiarisation ou de l'entraînement, il est préférable que les participants soient groupés (par trois, par exemple) pour qu'ils puissent communiquer aisément et échanger leurs impressions sur les défauts qu'ils détectent.

L'Appendice 3, «Exemple d'instructions destinées aux auditeurs», donne, à titre d'exemple, un jeu d'instructions avec une description de la technique de «doublement aveugle à triple stimulus et référence dissimulée» de présentation du stimulus. Une familiarisation bien menée peut convertir des participants initialement peu doués en des experts pour les besoins de l'essai. A l'issue de la familiarisation, les participants doivent avoir acquis une connaissance précise de l'échelle qu'ils auront à utiliser dans la phase de notation qui succédera à la familiarisation ou à l'entraînement.

4.2 Phase de notation

Au début de la première séance réelle de notation de la journée, il faut présenter oralement à chaque participant les instructions pour les essais, complétés de préférence par des documents écrits. On peut effectuer à titre d'exemple plusieurs comparaisons juste avant le début des présentations pour la notation.

Comme la mémoire auditive à long et moyen terme n'est pas fiable, la procédure d'essai ne devra faire appel qu'à la mémoire à court terme. On y parvient au mieux avec une méthode de commutation quasi instantanée (voir la Note 1) associée au système à triple stimulus que décrit l'Appendice 3. Ce type de commutation exige une coordination temporelle très précise des stimulus.

NOTE 1 – Une commutation rigoureusement instantanée peut créer des défauts si les signaux des stimulus successifs ne sont pas les mêmes. On préférera une commutation quasi instantanée avec, par exemple, un délai de 40 ms en cas de disparition/changement/réapparition.

Dans les évaluations les plus critiques, un seul participant intervient à la fois. Ce n'est qu'ainsi qu'il peut, en toute liberté, passer d'un stimulus à l'autre dans la méthode à trois stimulus. Il est essentiel qu'il ait cette faculté pour explorer librement toutes les comparaisons entre les stimulus de chaque essai.

Il est préférable qu'il puisse effectuer les commutations entre stimuli sans information visuelle, les yeux fermés s'il le veut, pour mieux se concentrer et être moins distrait. Il ne faut pas que la commutation introduise le moindre bruit parasite (comme des «clics»), car ce genre de parasite risque de perturber gravement le processus d'évaluation.

Une séance de notation ne devrait pas durer plus de 20 à 30 min mais si, comme cela a été préconisé, le rythme des essais est laissé à la discrétion des participants, la durée variera de façon arbitraire de l'un à l'autre. D'après l'expérience acquise, il semble qu'il ne faut pas prévoir plus de 10 à 15 essais par séance pour obtenir la durée voulue. La fatigue des participants est de nature à affecter sérieusement la validité des jugements portés. Pour l'éviter, il sera prévu pour chaque participant et entre les séances successives, un repos de durée égale ou inférieure à celle de la séance.

5 Caractéristiques

Les caractéristiques spécifiques des évaluations monophoniques, stéréophoniques et multivoies sont énumérées ci-après. On préfère évaluer, dans chaque cas, la caractéristique «qualité audio de base». Les expérimentateurs peuvent choisir de définir et d'évaluer d'autres caractéristiques.

Si on demande aux participants d'essayer d'évaluer plus d'une caractéristique au cours de chaque essai, il se peut qu'ils aient du mal à répondre. S'ils se sentent perdus ou débordés du fait qu'ils tentent de répondre à plusieurs questions à propos d'un stimulus donné, il peut en résulter des notes peu fiables pour toutes ces questions.

5.1 Système monophonique

Qualité audio de base

- Cette caractéristique unique et globale sert à estimer toute différence décelée entre la référence et l'objet de l'essai.

5.2 Système stéréophonique à deux voies

Qualité audio de base

- Cette caractéristique unique et globale sert à estimer toute différence décelée entre la référence et l'objet de l'essai.

La caractéristique supplémentaire qui suit peut aussi être intéressante:

Qualité de l'image stéréophonique

- Cette caractéristique correspond aux différences entre la référence et l'objet de l'essai du point de vue de l'emplacement des images sonores, de l'impression de profondeur et de présence de l'événement audio.

Bien que des études aient montré que la qualité de l'image stéréophonique peut se dégrader, la question de savoir s'il est justifié de noter séparément la qualité de l'image stéréophonique et la qualité audio de base n'a pas fait l'objet de recherches suffisantes.

NOTE 1 – Jusqu'en 1993, pour la plupart des études d'évaluation subjective des dégradations faibles, on s'est servi uniquement de la caractéristique qualité audio de base. La caractéristique qualité de l'image stéréophonique était donc implicitement ou explicitement incluse dans la qualité audio de base en tant que caractéristique globale dans ces études.

5.3 Système stéréophonique multivoies

Qualité audio de base

- Cette caractéristique unique et globale sert à estimer toute différence décelée entre la référence et l'objet de l'essai.

La caractéristique supplémentaire qui suit peut aussi être intéressante:

Qualité frontale de l'image

- Cette caractéristique correspond à la localisation des sources sonores frontales. Elle comprend la qualité de l'image stéréophonique et les pertes de définition.

Impression de qualité ambiophonique

- Cette caractéristique correspond à l'impression d'espace, à l'ambiance ou aux effets spéciaux bidirectionnels d'immersion.

6 Éléments de programme

Il ne faut employer que des éléments critiques pour révéler les différences entre les systèmes soumis aux essais. Les éléments critiques sont ceux qui mettent à l'épreuve ces systèmes. Il n'existe pas d'éléments de programme universels «convenables» pour évaluer tous les systèmes dans toutes les conditions. Il faut donc trouver, pour chaque système à tester dans chaque expérience, un élément de programme critique. La recherche de l'élément approprié prend en général du temps; toutefois, faute d'avoir trouvé les éléments critiques pour chaque système, l'expérience ne saura révéler les différences entre systèmes et ne sera pas probante.

Il faut, avant qu'une conclusion «nulle» soit tenue pour valable, s'assurer de façon empirique ou statistique que, si on ne parvient pas à trouver des différences entre systèmes, ce n'est pas parce que l'expérience ne les décèle pas en raison d'un mauvais choix des éléments audio ou encore parce qu'elle est mal organisée. Dans le cas extrême où l'on constate que tous les systèmes ou une majorité d'entre eux sont parfaitement transparents, il peut être nécessaire de prévoir des essais spéciaux avec des notes faibles ou moyennes afin de vérifier expressément la compétence des participants (voir l'Appendice 1).

Il doit être établi, à partir de recherches préalables par exemple, que ces repères peuvent être détectés par des auditeurs très expérimentés, mais non pas par des auditeurs inexpérimentés. Ces repères sont introduits en tant qu'éléments d'essai afin de vérifier non seulement la compétence des participants mais encore la sensibilité de tous les autres aspects des conditions expérimentales.

Si ces repères, qu'ils soient intégrés de manière non prévisible dans le contexte d'éléments apparemment transparents ou qu'ils soient intégrés dans un essai distinct, sont correctement identifiés par tous les auditeurs dans le cadre d'une méthode d'essai type (voir le § 3 de la présente Annexe) avec application des considérations statistiques indiquées dans l'Appendice 1, on peut alors conclure que la compétence des auditeurs est acceptable et qu'il n'y a pas de problème de sensibilité en ce qui concerne les autres aspects des conditions expérimentales. Dans ce cas alors, les résultats de transparence apparente établis par ces auditeurs sont une preuve de «vraie transparence» pour les éléments ou les systèmes pour lesquels ces auditeurs n'ont pu différencier la version codée de celle non codée.

Par ailleurs, si ces repères ne peuvent être correctement identifiés par n'importe quel auditeur, on peut alors en conclure soit que ces auditeurs ne sont pas assez compétents, soit qu'il y a des défauts de sensibilité dans le cadre expérimental même, soit que ces deux facteurs sont associés. Dans ce cas, la transparence apparente des systèmes ne peut être interprétée de manière adéquate et il faudra renouveler l'expérience avec de nouveaux auditeurs pour remplacer ceux qui n'ont pu réussir cet essai supplémentaire et apporter toute autre modification susceptible d'accroître la sensibilité expérimentale.

Dans la recherche d'éléments critiques, il faut accepter tout stimulus qui pourrait se présenter dans un programme radiodiffusé. On ne tiendra pas compte des signaux synthétisés spécialement conçus pour perturber le fonctionnement d'un système. Le contenu artistique ou intellectuel d'une séquence de programme ne sera ni intéressant, ni déplaisant, ni fatigant au point de détourner le participant de la recherche des dégradations. Il sera tenu compte de la probabilité d'apparition de chaque type d'élément de programme dans les diffusions réelles. Il faut toutefois se souvenir que la nature des éléments de programme peut changer en fonction de l'évolution des styles musicaux et de la mode. A l'avenir, des modèles perceptuels objectifs pourraient aider à choisir les éléments critiques.

Lorsqu'on sélectionne les éléments de programme, il est important de définir avec précision les caractéristiques à évaluer. Il faut confier cette tâche à des participants expérimentés ayant une connaissance de base des dégradations prévues. Ils doivent disposer au départ d'une vaste gamme d'éléments que l'on peut élargir au moyen d'enregistrements spécialisés.

En vue de la préparation de bandes d'essai pour comparaison subjective, il faut qu'un groupe de participants expérimentés règle le niveau sonore de chaque extrait avant de l'enregistrer sur le support des essais. On pourra ensuite se servir de ce support pour régler de façon fixe le gain de tous les éléments de programme.

Pour toutes les séquences d'essai, le groupe de participants expérimentés devra donc se réunir et convenir de façon unanime des niveaux sonores relatifs de chaque extrait. En outre, les experts devront parvenir à un accord sur le niveau de pression acoustique absolu reproduit par rapport au niveau d'alignement pour l'ensemble d'une séquence.

Au début de chaque enregistrement, il y aura une salve de tonalités (par exemple, 1 kHz, 300 ms, -18 dBFS) (FS: full scale – échelle totale) au niveau du signal d'alignement de façon qu'on puisse régler le niveau d'alignement à la sortie sur le niveau d'alignement à l'entrée exigé par le canal de reproduction (voir le § 8.4.1). Pour les éléments d'essai en enregistrement numérique, le niveau d'alignement doit correspondre à -18 dB par rapport au niveau de codage maximal possible du système numérique [UER, 1992]. Il faut contrôler le signal radiophonique de façon que les crêtes d'amplitude ne dépassent que rarement l'amplitude de crête maximale permise pour le signal (voir la Recommandation UIT-R BS.645; signal sinusoïdal à 9 dB au-dessus du niveau d'alignement). A noter que, dans ces conditions, un indicateur de crête indiquera des niveaux qui ne dépassent pas le niveau de signal maximal autorisé. La salve de tonalités peut aussi être utile pour l'alignement dans le temps de la référence et les stimulus d'essai.

Le nombre d'extraits que l'on peut inclure dans un essai est variable: il doit être égal pour chaque objet d'essai. Un nombre raisonnable serait de 1,5 fois le nombre d'objets, pourvu qu'il y ait au moins 5 extraits. En général, les extraits audio durent de 10 à 25 s. Etant donné la difficulté de la tâche, il faut que le ou les objets soient disponibles. La sélection ne sera réussie que si on a défini un horaire approprié.

Pour l'évaluation des systèmes monophoniques et stéréophoniques, il serait intéressant que les extraits proviennent de sources aisément accessibles pour que l'on puisse vérifier directement les bandes préparées en les comparant aux originaux, si besoin est. Le disque compact SQAM est un exemple de source de ce genre. Il est toutefois plus important d'utiliser des extraits vraiment critiques même s'ils proviennent de sources d'accès plus difficile.

On vérifiera le fonctionnement d'un système multivoies en reproduction à deux voies au moyen d'un mixage réducteur de référence. Bien que dans certains cas, on puisse estimer que le recours à un mixage réducteur fixe est restrictif, c'est certainement à long terme l'option la plus raisonnable pour les radiodiffuseurs. Les formules du mixage réducteur de référence sont les suivantes (voir la Recommandation UIT-R BS.775):

$$L_0 = 1,00 L + 0,71 C + 0,71 L_s$$

$$R_0 = 1,00 R + 0,71 C + 0,71 R_s$$

La présélection d'extraits pour essai adaptés à l'évaluation critique du fonctionnement du mixage réducteur de référence à deux voies devrait être fondée sur la reproduction des éléments de programme à mixage réducteur à deux voies.

7 Dispositifs de reproduction

7.1 Généralités

On choisira les haut-parleurs et les casques de contrôle de référence de manière qu'ils reproduisent au mieux les signaux radiophoniques et les autres signaux d'essai; ainsi, quel que soit le type de reproduction, ils doivent donner un son neutre et pouvoir servir aux évaluations tant en monophonie qu'avec les systèmes sonores stéréophoniques à deux voies ou plus.

Certains défauts sont plus perceptibles avec une reproduction au casque et d'autres par haut-parleurs. Il faudra donc déterminer au moyen d'essais subjectifs préliminaires quel est le mode de reproduction approprié.

Dans le cas particulier des défauts qui affectent les caractéristiques de l'image sonore stéréophonique, on choisira la reproduction par haut-parleurs.

Pour évaluer les systèmes sonores stéréophoniques à deux voies, il peut être nécessaire d'utiliser à la fois des haut-parleurs stéréophoniques et des casques. Pour évaluer les systèmes sonores monophoniques, on peut utiliser un haut-parleur central ou des casques.

Si on a le choix entre les haut-parleurs ou les casques pour des essais isolés ou groupés, on pourra trouver la corrélation entre l'importance auditive d'un phénomène et l'appareil utilisé mais le nombre effectif des participants en sera diminué. En revanche, si les participants peuvent passer librement des haut-parleurs aux casques, il ne sera pas possible de trouver la corrélation entre l'usage d'un appareil et l'importance auditive du phénomène.

Pour évaluer les systèmes sonores multivoies avec ou sans image associée, il faut recourir aux haut-parleurs si l'on veut évaluer ce qui se passe pour tous les canaux de reproduction employés simultanément.

Quoiqu'il en soit, il faut que tous les haut-parleurs soient acoustiquement homogènes dans la bande de fréquences utile, de façon que les différences de timbre entre eux soient aussi faibles que possible.

7.2 Haut-parleur de contrôle de référence

7.2.1 Généralités

Le «haut-parleur de contrôle de référence» désigne un équipement d'écoute de haute qualité pour studio qui comprend un ensemble intégré de haut-parleurs dans une enceinte de dimensions spécifiques et une égalisation spéciale, d'excellents amplificateurs de puissance et les réseaux de transition appropriés.

Les caractéristiques électroacoustiques doivent répondre aux exigences minimales suivantes mesurées en espace libre. Les niveaux sonores absolus correspondent à une distance de mesure de 1 m par rapport au centre acoustique, sauf mention contraire.

7.2.2 Exigences électroacoustiques

7.2.2.1 Courbe amplitude fréquence

Pour la présélection des haut-parleurs, la courbe de réponse en fréquence dans la gamme 40 Hz-16 kHz, mesurée sur l'axe principal (azimut = 0°) au moyen de bruit rose dans des bandes d'un tiers d'octave, doit de préférence tenir dans une bande de tolérance de 4 dB. Les courbes de réponse en fréquence mesurées pour des azimuts de $\pm 10^\circ$ ne doivent pas s'écarter de plus de 3 dB de la réponse sur l'axe et de plus de 4 dB pour des azimuts de $\pm 30^\circ$ (uniquement dans le plan horizontal).

Les réponses en fréquence des divers haut-parleurs doivent se correspondre. Dans la gamme de fréquences comprises au moins entre 250 Hz et 2 kHz, il est préférable qu'elles ne s'écarterent pas les unes des autres de plus de 1,0 dB.

NOTE 1 – La courbe de réponse du local utilisé, mentionnée au § 8.3.4, décrit la caractéristique de fréquence dans le champ sonore du local d'écoute.

7.2.2.2 Indice de directivité

L'indice de directivité C , mesuré pour les fréquences comprises entre 500 Hz et 10 kHz avec un bruit de largeur de bande d'un tiers d'octave, doit satisfaire à l'équation suivante:

$$6 \text{ dB} \leq C \leq 12 \text{ dB}$$

L'indice de directivité doit augmenter régulièrement avec la fréquence.

7.2.2.3 Distorsion non linéaire

Un signal d'entrée à tension constante qui produit un niveau de pression acoustique moyen de 90 dB est appliqué au haut-parleur. Avec cette pression, aucune composante de distorsion harmonique, dans la gamme des fréquences fondamentales de 40 Hz à 16 kHz, ne doit dépasser les valeurs suivantes:

$$\begin{array}{ll} -30 \text{ dB (3\%)} & \text{pour } f < 250 \text{ Hz} \\ -40 \text{ dB (1\%)} & \text{pour } f \geq 250 \text{ Hz} \end{array}$$

7.2.2.4 Restitution des transitoires

Mesuré à l'oscilloscope, le temps de descente jusqu'au niveau à $1/e$ (soit environ 0,37) du niveau de départ (sur l'axe principal seulement) doit être:

$$t_s < 5 / f$$

où f est la fréquence.

Autrement dit, le temps de descente d'une salve de tonalité sinusoïdale ne doit pas dépasser 5 fois la période de l'onde sinusoïdale correspondante.

7.2.2.5 Temps de propagation

La différence de temps de propagation entre les voies d'un système stéréophonique ou multivoies ne doit pas dépasser 100 μs .

NOTE 1 – Cela n'inclut pas le temps de propagation entre le haut-parleur et la position d'écoute.

Dans le cas d'un système avec image associée, le temps de propagation global du haut-parleur de contrôle de référence par rapport au ou aux systèmes étudiés ne doit pas dépasser les limites imposées dans la Recommandation UIT-R BS.775.

7.2.2.6 Dynamique

Le niveau de fonctionnement sonore maximal qu'un haut-parleur peut produire pendant au moins 10 min sans dégâts d'ordre thermique ou matériel et sans surcharge des circuits actifs, mesuré avec un signal de bruit imitant un programme (conformément à la Publication 268-1c de la Commission électrotechnique internationale (CEI)) doit être:

$$L_{eff \text{ max}} > 108 \text{ dB}$$

mesuré au moyen d'un sonomètre à réponse uniforme et en position valeur quadratique moyenne (lent).

Le niveau équivalent de bruit acoustique émis par un seul haut-parleur de contrôle de référence et son amplificateur associé, à une distance de 1 m de son centre acoustique (voir la Note 1) doit être:

$$L_{bruit} < 10 \text{ dBA}$$

NOTE 1 – Le centre acoustique est le point de référence pour les mesures. Il correspond d'habitude au centre géométrique de la surface qui rayonne les fréquences les plus élevées du haut-parleur. Il devra être indiqué par le constructeur.

7.3 Ecouteurs de contrôle de référence

7.3.1 Généralités

Il s'agit d'un matériel d'écoute de haute qualité pour studio, égalisé en fonction de la réponse en champ diffus.

7.3.2 Exigences électroacoustiques

7.3.2.1 Réponse en fréquence

La réponse en fréquence en champ diffus des casques de contrôle pour studio est précisée dans la Recommandation UIT-R BS.708.

7.3.2.2 Temps de propagation

La différence de temps de propagation entre les voies d'un système stéréophonique ne doit pas dépasser 20 μ s.

Dans le cas d'un système avec image associée, le temps de propagation global des casques de contrôle de référence combinés au ou aux systèmes étudiés ne doit pas dépasser les limites imposées dans la Recommandation UIT-R BS.775.

8 Conditions d'écoute

8.1 Généralités

L'expression «conditions d'écoute» désigne les exigences acoustiques complexes imposées à un champ sonore de référence que subit un auditeur dans un local d'écoute, au point d'écoute de référence, en présence de sons reproduits par des haut-parleurs. Ces conditions d'écoute recouvrent:

- les propriétés acoustiques du local d'écoute,
- la disposition des haut-parleurs dans le local d'écoute,
- l'emplacement du point ou de la zone d'écoute de référence,

qui produisent les caractéristiques du champ sonore résultant en ce point ou en cette zone.

Comme l'état actuel de la technique ne permet pas encore de fournir une description du champ sonore de référence au moyen des seuls paramètres acoustiques, on indiquera certaines exigences géométriques et acoustiques imposées au local d'écoute de référence afin de garantir que les conditions d'écoute décrites sont viables.

8.2 Local d'écoute de référence

8.2.1 Généralités

Dans le cas de la reproduction par haut-parleurs, les essais subjectifs doivent satisfaire aux exigences suivantes. Les exigences minimales imposées aux locaux d'écoute sont décrites ci-dessous.

Dans le cas de la reproduction au casque uniquement, le local d'écoute doit satisfaire au moins aux exigences concernant le niveau de bruit ambiant.

8.2.2 Propriétés géométriques

On trouvera ci-après les dimensions nettes qui conviennent à un local d'écoute de référence. Si elles ne peuvent être obtenues, il faut au moins satisfaire aux conditions imposées ci-dessous au champ sonore et à la disposition des haut-parleurs.

8.2.2.1 Dimensions du local (surface au sol)

- Pour une reproduction monophonique ou stéréophonique à deux voies: 20-60 m².
- Pour une reproduction stéréophonique multivoies: 30-70 m².

NOTE 1 – Avec les plus faibles valeurs ci-dessus, le nombre d'auditeurs qu'il est possible de recevoir ensemble sera limité.

8.2.2.2 Forme du local

Le local doit être symétrique par rapport au plan vertical médiateur de la base stéréo. La surface au sol aura de préférence la forme d'un rectangle ou d'un trapèze.

8.2.2.3 Proportions du local

Les rapports des dimensions du local devront satisfaire aux relations suivantes pour que la distribution des tonalités propres à basse fréquence du local soit raisonnablement uniforme:

$$1,1 l/h \leq L/h \leq 4,5 l/h - 4$$

où:

L: longueur

l: largeur

h: hauteur.

On respectera en outre les conditions $L/h < 3$ et $l/h < 3$.

8.2.3 Propriétés acoustiques du local

8.2.3.1 Temps de réverbération

La valeur moyenne du temps de réverbération, T_m , dans la gamme de fréquences comprises entre 200 Hz et 4 kHz, doit être:

$$T_m = 0,25 (V / V_0)^{1/3} \quad \text{s}$$

où:


V: volume du local

V_0 : volume de référence de 100 m³.

La Fig. 1 présente les tolérances valables pour T_m dans la gamme comprise entre 63 Hz (voir la Note 1) et 8 kHz.

NOTE 1 – Il est difficile de mesurer de faibles temps de réverbération aux basses fréquences.

FIGURE 1
Limites des tolérances pour le temps de réverbération, rapportées à sa valeur moyenne T_m



8.3 Caractéristiques du champ sonore de référence

8.3.1 Généralités

Les caractéristiques du champ sonore dans la zone d'écoute exercent une influence déterminante sur la perception subjective et sur l'évaluation de la qualité des phénomènes audibles et de leur reproductibilité à d'autres emplacements ou dans d'autres locaux. Ces caractéristiques résultent de l'interaction du ou des haut-parleurs et du local d'écoute et correspondent au dispositif d'écoute utilisé (voir le § 8.5).

On peut actuellement décrire les caractéristiques suivantes.

8.3.2 Son direct

8.3.2.1 Réponse en fréquence du haut-parleur de contrôle

La courbe de réponse du ou des haut-parleurs mesurée en espace libre doit répondre aux exigences exposées au § 7.2.2.

8.3.3 Son réfléchi

8.3.3.1 Réflexions rapides

Les réflexions rapides dues aux parois du local d'écoute, qui arrivent dans la zone d'écoute moins de 15 ms après le son direct, doivent être affaiblies dans la gamme 1-8 kHz d'au moins 10 dB par rapport au son direct.

8.3.3.2 Traîne sonore

En plus des exigences spécifiques imposées aux réflexions rapides et à la réverbération (voir le § 8.2.3), il faut éliminer d'autres anomalies significatives du champ sonore, comme les échos flottants (flutter), la coloration sonore, etc.

8.3.3.3 Temps de réverbération

(Voir le § 8.2.3.1.)

8.3.4 Champ sonore stationnaire

8.3.4.1 Courbe de réponse du local d'écoute

Les courbes de réponse du local d'écoute sont définies comme étant les courbes de réponse d'un tiers d'octave des niveaux de pression acoustique produite par chaque haut-parleur au point d'écoute de référence, avec un bruit rose dans la gamme de fréquences 50 Hz-16 kHz. Il faut que les courbes de réponse du local d'écoute mesurées soient comprises dans les limites de tolérances de la Fig. 2.

Les écarts entre les diverses courbes de réponse du local d'écoute pour chacun des haut-parleurs frontaux (stéréo ou multivoies) au point d'écoute de référence ne doivent pas excéder 2 dB dans toute la gamme de fréquences.

8.3.4.2 Bruit de fond

Il est préférable que le bruit de fond continu (dû à la climatisation, aux appareils internes ou à d'autres sources extérieures), mesuré dans la zone d'écoute à 1,2 m au-dessus du sol ne dépasse pas la courbe NR 10 (voir les Fig. 3 et 4).

En aucune circonstance le bruit de fond ne dépassera la courbe NR 15.

Il ne faut pas que le bruit de fond apparaisse comme impulsif, cyclique ou sinusoïdal.

8.4 Niveau d'écoute


8.4.1 Ecoute sur haut-parleurs

8.4.1.1 Niveau de pression acoustique de travail (niveau d'écoute de référence)

On définit le niveau d'écoute de référence comme le niveau d'écoute préféré pour un signal de mesure donné, écouté au point de référence. Il caractérise le gain acoustique du canal de reproduction afin de garantir l'obtention du même niveau de pression acoustique pour un même extrait dans des locaux d'écoute différents.


L'alignement des niveaux de chacun des haut-parleurs dans une disposition d'écoute donnée s'effectuera au moyen d'un bruit rose.

FIGURE 2
 Limites des tolérances pour la courbe de réponse du local d'écoute



1116-02

FIGURE 3
 Limites du bruit de fond par bande d'un tiers d'octave
 (Courbes d'évaluation du bruit (NR) fondées sur les précédentes courbes NR de l'ISO, Recommandation ISO R1996 (1972))




Courbes d'évaluation du bruit NR 10 (recommandée) et NR 15 (maximum)

1116-03

FIGURE 4

Limites du bruit de fond par octave
(Courbes d'évaluation du bruit (NR) fondées sur les
précédentes courbes NR de l'ISO, Recommandation ISO R1996 (1972))



Courbes d'évaluation du bruit NR 10 (recommandée) et NR 15 (maximum)

1116-04

Pour un signal de mesure de tension efficace égale au «niveau du signal d'alignement» (0 dBµ0s, selon la Recommandation UIT-R BS.645; -18 dB au-dessous du niveau d'écrêtage d'un enregistrement numérique sur bande, selon [UER, 1992]), appliqué successivement à l'entrée de chaque canal de reproduction (c'est-à-dire un amplificateur de puissance et son haut-parleur associé), il faut régler le gain de l'amplificateur de façon à obtenir le niveau de pression acoustique de référence (CEI/pondération A, lent).

$$L_{réf} = 85 - 10 \log n \pm 0,25 \quad \text{dBA}$$

où n est le nombre de canaux de reproduction dans l'ensemble du dispositif.

NOTE 1 – Cette hypothèse de gains des canaux égaux peut ne pas convenir pour certains éléments du programme source.

(Au cours des séquences d'essai précédentes, on a noté que chaque auditeur peut préférer des niveaux absolus d'écoute différents. Bien que ce ne soit pas la meilleure solution, on ne peut pas toujours empêcher les participants de demander autant de souplesse. On ne sait pas encore si cela aura une influence sur l'audibilité de certains des défauts étudiés. Par conséquent, si les participants eux-mêmes règlent le gain du système, il faudra le mentionner dans le résultat des essais.)

8.4.2 Reproduction au casque

Il faut régler le niveau de façon à obtenir une intensité sonore égale au champ sonore de référence produit par des haut-parleurs. Pour apprécier cette égalité de niveau, il faut que le participant se trouve au point d'écoute de référence.

8.5 Dispositions d'écoute

8.5.1 Généralités

La disposition d'écoute décrit la position des haut-parleurs et les points d'écoute (zone d'écoute) dans le local d'écoute.

En principe, les essais d'écoute s'effectuent aux positions d'écoute de référence et à d'autres positions recommandées. Il faut toutefois évaluer ce qui se passe si l'écoute n'a pas lieu près du centre. C'est pourquoi on envisage les positions d'écoute du «cas le plus défavorable».

8.5.1.1 Hauteur et orientation des haut-parleurs de contrôle


La hauteur de tous les haut-parleurs de contrôle, mesurée au centre acoustique du haut-parleur, doit être d'environ 1,2 m au-dessus du sol. Cela correspond à la hauteur de l'oreille d'un auditeur assis. Les haut-parleurs seront orientés de telle manière que leurs axes de référence passent à une hauteur de 1,2 m à la position de référence.

8.5.1.2 Distance jusqu'aux murs

Pour des haut-parleurs sur support indépendant, le centre acoustique du haut-parleur doit se situer à au moins 1 m des surfaces de réflexion d'enceinte.

8.5.2 Reproduction monophonique (Fig. 5)

Pour la reproduction des signaux monophoniques, on ne doit utiliser qu'un haut-parleur. La distance d'écoute est d'au minimum 2 m et toutes les positions d'écoute doivent se trouver dans un angle de $\pm 30^\circ$ par rapport à l'axe du haut-parleur.




D : distance d'écoute

1116-05

8.5.3 Reproduction stéréophonique à deux voies (Fig. 6)

FIGURE 6

Disposition pour essais d'écoute avec haut-parleurs L et R
Systèmes sonores stéréophoniques avec faibles dégradations



 Position d'écoute de référence

 Positions d'écoute les plus défavorables

B : largeur de la base des haut-parleurs
 D : distance d'écoute

1116-06

8.5.3.1 Largeur de la base, B

La largeur de base B sera comprise de préférence entre 2 et 3 m. Dans des locaux de conception appropriée, elle peut atteindre 4 m.

8.5.3.2 Distance d'écoute, D (distance du haut-parleur à l'auditeur)

La distance d'écoute D sera comprise entre 2 et $1,7 B$ (m).

8.5.3.3 Positions d'écoute


Le point d'écoute dit de référence est défini par un angle d'écoute de 60°.

La zone d'écoute recommandée ne doit pas décrire un rayon supérieur à 70 cm autour du point d'écoute de référence. La Fig. 6 présente aussi d'autres positions d'écoute dans le «cas le plus défavorable».

8.5.4 Reproduction stéréophonique multivoies (Fig. 7)

La disposition d'écoute doit, en principe, correspondre à l'arrangement sonore multivoies 3/2 que spécifie la Recommandation UIT-R BS.775, Fig. 1 «Disposition de référence des haut-parleurs avec haut-parleurs L/C/R et LS/RS».

FIGURE 7
Disposition pour essais d'écoute avec haut-parleurs L/C/R et LS/RS
Systèmes sonores multivoie avec de faibles dégradations



-  Position d'écoute de référence
-  Positions d'écoute les plus défavorables

B: largeur de la base des haut-parleurs
D: distance d'écoute

8.5.4.1 Largeur de la base, B

La largeur de base B sera comprise de préférence entre 2 et 3 m. Dans des locaux de conception appropriée, elle peut atteindre 5 m.

8.5.4.2 Distance d'écoute et angle de base

La distance d'écoute de référence sera B et l'angle de base de référence est donc égal à 60° .

8.5.4.3 Positions d'écoute

Le point d'écoute dit de référence est défini par un angle d'écoute de 60° comme ci-dessus. La Fig. 7 présente aussi d'autres positions d'écoute dans le «cas le plus défavorable».

9 Analyse statistique

L'analyse statistique des résultats des essais vise principalement à déterminer avec précision la qualité moyenne de chacun des systèmes soumis aux essais et la validité des différences relevées entre ces appréciations de qualité moyenne. Pour mesurer cette validité, il faut connaître la variabilité ou la variance des résultats.

Si les essais ont été effectués conformément aux procédures décrites dans les autres parties de la présente Recommandation, il y a des chances pour que l'échelle soit régulière, c'est-à-dire que chaque échelon de l'échelle d'évaluation soit approximativement égal aux autres. Toutefois, aucune méthode statistique particulière n'est ni interdite ni recommandée pour obtenir cette propriété de l'échelle.

Pourvu que les hypothèses qui sous-tendent les statistiques paramétriques soient assez bien satisfaites, cette méthode se révèle la plus sensible et la plus efficace et elle est donc recommandée. Ce n'est que lorsqu'on constate que des propriétés importantes des données sont très différentes des hypothèses que sous-tend le modèle ANOVA (analyse de la variance – analysis of variance) qu'il convient d'envisager d'autres méthodes d'analyse (non paramétriques, par exemple). Il est précisément conseillé de commencer l'analyse en utilisant le modèle ANOVA. Par la suite, d'autres méthodes comme celle de l'essai t , de Neuman-Keuls, de Scheffe, etc., qui utilisent des estimations de la variance fournies par l'ANOVA peuvent servir à étudier plus en détail les secteurs où l'on observe les effets globaux significatifs révélés par ANOVA (le cas échéant).

Une hypothèse spécifique peut souvent être validée au moyen de plusieurs méthodes statistiques différentes. La légitimité d'une décision peut être renforcée si une hypothèse particulière apparaît convenir aussi pour une validation avec une autre méthode statistique. Il est donc suggéré d'appliquer une analyse des données supplémentaire (comme Wilcoxon, etc.).

Il est aussi important, à un moment donné, de considérer les aspects psychométriques qui influencent certainement le type de conclusions intéressantes que l'on peut obtenir avec une échelle non matérielle.

Il convient de noter qu'à moins que l'échelle d'évaluation ne s'avère linéaire, les comparaisons de notes différentes ne peuvent se faire que sur la base de l'ordre de classement.

10 Présentation des résultats des analyses statistiques

10.1 Généralités

Il faut une présentation avec laquelle le lecteur non averti aussi bien que l'expert puisse trouver les informations pertinentes. Tout lecteur veut d'abord voir le résultat global de l'expérience, sous forme graphique de préférence. Une telle présentation pourra être enrichie d'informations quantitatives plus détaillées mais les analyses numériques détaillées seront consignées dans des appendices.

10.2 Notes absolues

Grâce à une présentation des notes moyennes absolues, pour l'objet des essais et la référence dissimulée, on peut avoir un bon aperçu initial des données.

Il ne faut toutefois pas oublier que cette présentation ne saurait servir de base à une analyse statistique détaillée. En effet, quand on recourt à la méthode d'essai recommandée ici, le participant sait bien qu'une des sources de la paire à comparer est identique à la référence. Les observations ne sont donc pas indépendantes et l'analyse statistique de ces notes absolues ne conduira pas à une information significative, de sorte qu'il ne faut pas entreprendre cette analyse.

10.3 Notation des différences

La différence entre les notes données à la référence dissimulée et à l'objet de l'essai est un bon élément pour une analyse statistique. Une présentation graphique montre de combien on s'écarte vraiment de la transparence, ce qui est en principe du plus haut intérêt.

10.4 Niveau de signification et intervalle de confiance

Le rapport d'essai doit fournir au lecteur des renseignements sur la nature intrinsèquement statistique de toutes les données subjectives. Il convient d'indiquer les niveaux de signification ainsi que d'autres détails sur les méthodes statistiques et les résultats, comme l'inclusion des intervalles de confiance ou des intervalles d'erreur dans les graphiques, pour aider le lecteur à comprendre les conclusions.

Il n'existe pas naturellement de niveau de signification «correct». Toutefois, on retient en général la valeur de 0,05. On peut en principe utiliser des essais à une ou deux sorties selon les hypothèses vérifiées.

11 Contenu des rapports d'essai

Les rapports d'essai doivent exposer, aussi clairement que possible, les principes de l'étude, les méthodes mises en œuvre et les conclusions obtenues. Il faut donner suffisamment de détails pour qu'une personne compétente puisse en principe reprendre l'étude pour en vérifier les résultats de façon empirique. Un lecteur qui connaît le sujet doit être capable de comprendre et de critiquer les points les plus importants de l'essai comme les raisons profondes de l'étude, les méthodes expérimentales et la réalisation ainsi que les analyses et les conclusions.

On s'attachera particulièrement aux aspects suivants:

- la spécification et la sélection des participants et des extraits,
- les précisions pratiques sur l'environnement et le matériel d'écoute, y compris les dimensions et les caractéristiques acoustiques du local, le type et l'emplacement des appareils de reproduction, la spécification de l'équipement électrique,
- la conception de l'expérience, l'entraînement, les instructions, les séquences de l'expérience, les procédures d'essai, la production des données,
- le traitement des données, y compris des précisions sur les statistiques déductives descriptives et analytiques,
- les bases précises de toutes les conclusions obtenues.

RÉFÉRENCE BIBLIOGRAPHIQUES

POULTON, E.C. [1992] Bias in quantifying judgments. Lawrence Erlbaum Associates, Hillsdale, Etats-Unis d'Amérique.

UER [1992] Recommandation R-68. Niveau d'alignement dans les équipements numériques de production du son ainsi que dans les magnétoscopes numériques. Union européenne de radio-télévision, Genève, Suisse.

APPENDICE 1

DE L'ANNEXE 1

Aspects statistiques de la postsélection des participants**1 Evaluation de la compétence des auditeurs**

La méthode de doublement aveugle à triple stimulus et référence dissimulée fournit deux notes pour chaque essai et permet de comparer ces deux notes directement, participant par participant, et d'étudier ces comparaisons sur tous les essais pour chaque participant. A chaque essai, on peut calculer la différence algébrique entre les deux notes, en soustrayant bien sûr toujours le même ordre. Supposons que nous soustrayions la note de la référence dissimulée de celle de l'objet de l'essai.

Si le participant n'a pas été capable, dans l'ensemble, de distinguer correctement la référence dissimulée de l'objet, la moyenne de toutes les différences de notes pour ce participant et cet essai d'écoute sera nulle ou proche de zéro car, en moyenne, les différences positives et négatives tendront à s'équilibrer. Si le participant a été capable, dans l'ensemble, de distinguer correctement la référence dissimulée de l'objet, la moyenne des différences s'écartera de zéro côté négatif, car elles seront pour la plupart négatives.

Les données ainsi obtenues sont soumises à un essai t unilatéral pour évaluer la probabilité que la moyenne de la distribution pour chaque participant soit égale à zéro. Si cette hypothèse de nullité est rejetée pour un participant donné, on peut alors en conclure que les données correspondant à ce participant proviennent d'une distribution à moyenne supérieure à zéro, côté négatif, pour un niveau de confiance donné. On peut alors conclure que chaque participant pour lequel cette hypothèse est vraie a donné la preuve qu'il ou qu'elle n'était pas tout simplement en train de deviner; on pourrait plus exactement dire de ces participants qu'ils ont fait preuve d'une compétence suffisante pour justifier l'inclusion de leurs données dans les analyses finales des résultats expérimentaux. Les données correspondant aux autres participants – ceux qui surtout devinaient – peuvent être rejetées pour toute analyse complémentaire au moyen de ce critère statistique.

Il convient de rappeler que les recommandations qui font l'objet de l'intégralité de la présente Recommandation n'ont trait exclusivement qu'aux faibles dégradations. S'il s'avère, pour une raison ou une autre, que de nombreuses dégradations «importantes» sont introduites dans un essai, et non uniquement des «faibles», la méthode de postsélection appliquée aveuglément, comme indiqué ci-dessus, peut aboutir à des conclusions erronées ou inappropriées. Une dégradation «importante» signifie ici une dégradation relativement facile à détecter, même par des auditeurs «non-experts». Il est évident que quelques dégradations véritablement «faibles» (difficiles à détecter), incluses dans un contexte dans lequel la plupart des dégradations sont «importantes» (faciles à détecter) auront peu d'incidence dans un essai t tel que celui décrit ci-dessus. En conséquence, les experts qui jugent correctement les éléments ayant de faibles dégradations peuvent être confondus dans les résultats globaux avec les non-experts qui jugent en «devinant» ces éléments. Cette situation tient au fait que dans des évaluations d'essai t , les résultats pour des éléments à faible dégradation peuvent se perdre dans le bruit statistique, étant donné que l'ampleur de t est la plus importante pour les éléments à dégradation importante.

Même dans le meilleur des essais portant sur de «faibles dégradations», on trouvera presque toujours inévitablement des dégradations importantes ou faciles à détecter, même si elles sont loin de constituer la majorité des dégradations. Cela étant, il est recommandé pour effectuer exclusivement des essais t de postsélection suffisamment rigoureux dans ce cas d'exclure systématiquement toutes les dégradations «faciles» à détecter ou importantes de la procédure d'essai t pour évaluer les compétences des auditeurs. Il peut s'agir de tous les éléments qui ont reçu de faibles notes moyennes de tous les participants, par exemple, des différences comprises entre $-2,0$ et $-4,0$. Pour ces éléments, la majorité des participants auront discerné avec justesse l'objet de la référence dissimulée et l'inclusion de ces éléments dans l'essai t rendra plus difficile l'évaluation de la compétence différentielle des participants au lieu de la faciliter. En laissant de côté les éléments à dégradation importante dans l'analyse de l'essai t , on exagérerait ou on surestimerait la compétence apparente des participants.

Le cas contraire, c'est-à-dire dans lequel il existe un trop grand nombre d'éléments «véritablement transparents», a été exposé au § 5 du corps de la présente Recommandation. Dans ce cas, ce sont les éléments apparemment transparents («trop difficiles») qui pourraient être omis dans les essais t de postsélection. Les éléments spéciaux introduits en raison de leur caractère critique avéré auraient davantage d'importance dans les essais t . En laissant les éléments apparemment transparents dans l'essai t , on sous-estimerait la compétence des sujets.

En règle générale, les éléments qui sont de manière permanente soit «trop difficiles» soit «trop faciles» ne permettent pas de distinguer les experts compétents des autres.

Le seul avantage que présente la bonne utilisation d'essais t de postsélection est que l'adéquation des participants pour une expérience donnée est évaluée au moyen de leurs résultats au cours de cette expérience. Lors d'une série d'expériences impliquant les mêmes participants dans des expériences différentes, il se peut que même si tous les participants passent le test de postsélection, certains d'entre eux conviennent parfaitement pour un sous-ensemble d'expériences mais pas pour toutes les expériences, comme le montre la postsélection. Dans ce cas, les données correspondant à un participant particulier peuvent être acceptées ou rejetées selon le cas pour des résultats d'essai précis. On peut ainsi affirmer le concept «de compétence» mieux qu'en se fiant exclusivement à la présélection.

Il faut ici faire preuve de prudence. Un participant qui n'est pas suffisamment compétent ne peut fournir de bonnes données. En conséquence, il est tout à fait justifié de rejeter des données pour cause de compétence insuffisante, déterminée objectivement par une postsélection rigoureuse. Par ailleurs, il n'existe aucune garantie que les données provenant d'un participant qui a bien passé une postsélection d'essai t soient à coup sûr des données satisfaisantes. A titre d'exemple extrême, un participant peut très bien distinguer des objets des références dissimulées pour 100% des essais dans le cadre d'une expérience. Mais les données peuvent révéler qu'il ou qu'elle a donné une note de 1,0 à tous les objets soumis aux essais. En d'autres termes, l'ensemble total des données de ce participant peut correspondre à des valeurs de différence de $-4,0$ pour tous les essais.

Si l'on suppose que tous les autres participants dans la même expérience ont fait preuve d'une distribution «plus habituelle» des notes dans tous les essais, la structure de réponse très curieuse de ce participant particulier (valeurs de différence toutes de « $-4,0$ ») pourrait amener à la conclusion qu'il faut rejeter ces données. Toutefois, à l'exception peut-être d'un seul cas de toute évidence extrêmement déviant décrit ici à des fins d'exemple, il serait très difficile d'appliquer ces critères *a posteriori* en ce qui concerne l'acceptabilité des données. Cela reviendrait à délibérément modeler les données en fonction d'une préconception de l'expérimentateur plutôt qu'accepter la preuve empirique des résultats effectifs.

Ces méthodes *a posteriori* NE doivent PAS être employées. Tant que le nombre total de participants à une expérience est adéquat, même si les données d'un participant expert sont extrêmement déviantes, elles auront très peu d'influence négative sur l'ensemble total des données. Des résultats significatifs et reproductibles sont tout à fait habituels lorsque l'on procède à des expériences sensibles, même lorsque celles-ci comprennent des participants déviant mais experts. Une fois l'expérience menée à bien, en cas de doute sur la «valeur» des données, le seul recours consiste à refaire entièrement l'expérience, à l'aide d'un tout nouvel ensemble de participants en s'efforçant de corriger tout défaut éventuel dans les procédures expérimentales employées auparavant.

2 Evaluation complémentaire de la compétence des auditeurs

A mesure que la qualité des codecs à pertes fondés sur le mode perceptuel augmente, le nombre d'auditeurs assez compétents pour discerner les défauts de codage restants diminuera inévitablement. Un auditeur qui s'est montré suffisamment compétent lors d'un essai antérieur incluant des défauts assez «aisément audibles» peut ne pas être suffisamment compétent lors d'un essai dans lequel ces défauts plus aisément audibles n'ont pas été introduits. En outre, bien que le résultat t d'un auditeur puisse montrer qu'il est suffisamment expert pour l'expérience dans son ensemble, il peut ne pas être suffisamment expert pour faire des différences entre le signal de référence et un signal codé d'excellente qualité. Dans ce cas, les données du participant peuvent ajouter du «bruit statistique» aux données totales, ce qui masque les véritables différences perçues par d'autres participants.


APPENDICE 2

DE L'ANNEXE 1

Evaluation du niveau de compétence des participants

Actuellement, toutes les données d'un participant au cours d'un essai donné servent à évaluer son résultat t . Les données de tous les participants ayant obtenu des résultats t suffisamment élevés sont alors prises en compte dans l'ANOVA.

FIGURE 8

Méthode permettant de ne pas tenir compte des points de données avant l'essai t 

1116-08

Dans la présente proposition, nous suggérons que les essais t soient refaits plusieurs fois pour les sous-ensembles de données de chaque participant. A chaque renouvellement de l'essai, le critère d'évaluation du niveau de compétence du participant deviendra plus exact.

Le niveau de compétence d'un participant sera réévalué et si ce dernier a fait preuve de compétence suffisante, les données qui lui correspondent seront alors incluses dans l'ANOVA suivante. En conséquence, pour chaque essai renouvelé, le critère de niveau de compétence suffisant augmentera et une ANOVA sera effectuée avec les données des autres participants. Les critères proposés d'évaluation de la compétence sont indiqués ci-après.

Le processus est illustré à la Fig. 8 pour un ensemble de données hypothétique. Tout d'abord, on calcule l'écart moyen type pour les données du participant; cet écart servira ensuite à déterminer les résultats z (voir la Note 1) correspondant aux données de ce participant. A partir de là, tous les points de données d'un participant situés au-delà d'un certain critère ($\mu + \Delta 1 s$) ne seront pas pris en compte et un nouvel essai t sera fait pour les points de données restants. Comme on le voit sur la Figure, les points de données situés au-delà de $\mu + \Delta 1 s$ (la zone ombrée) ne sont pas pris en compte et les autres points de données (la zone non ombrée) sont utilisés dans l'essai t suivant. Si, pour les points de données restants, il ressort de l'essai t que le participant a la compétence suffisante, toutes les données de ce participant seront incluses dans l'ANOVA suivante. Si l'essai t révèle que le participant n'a pas la compétence suffisante, les données qui lui correspondent seront éliminées entièrement de toutes les ANOVA suivantes. On répète ensuite ce processus en appliquant des critères de compétence encore plus stricts, $\mu + \Delta 2 s$. On répète ensuite le processus N fois avec les critères $\mu + \Delta i s$ où $i = 0, 1, \dots, N$. On étudie actuellement des valeurs appropriées de $\Delta i s$ et de N à partir de données d'études précédentes menées à bien au CRC (Communications Research Center – Centre de recherches sur les communications, Canada).

NOTE 1 – Les résultats z représentent les résultats normalisés pour une distribution à zéro de moyenne et un écart type de 1. Le résultat est défini comme suit $z = \frac{x - \mu}{s}$ où x est le point de données, μ est la moyenne d'échantillon et s est l'écart type pour l'échantillon:

$$s = \sqrt{\frac{N \sum x^2 - (\sum x)^2}{N(N - 1)}}$$

APPENDICE 3

DE L'ANNEXE 1

Exemple d'instructions données aux participants

La terminologie de ces instructions n'est pas strictement conforme aux définitions du glossaire.

1 Familiarisation ou phase d'entraînement

La phase d'entraînement a pour but de permettre aux auditeurs d'identifier les distorsions et déformations possibles du système soumis aux essais et de se familiariser avec elles. Après l'entraînement, vous devez être capable de savoir «ce qu'il faut rechercher à l'écoute». On vous demandera, dans l'après-midi, de noter en aveugle le matériel audio que vous entendrez le matin. Au cours de la phase d'entraînement, vous vous familiariserez aussi avec la procédure d'essai.

Vous entendrez une version de référence (originale) et une version modifiée de chaque élément du matériel audio. Sur l'écran de contrôle vidéo, la version de référence sera identifiée par la lettre «A»; la version du signal modifiée et la «référence dissimulée» seront désignées par les lettres «B» et «C». Au cours de la présentation, vous pouvez passer librement de l'une à l'autre de ces trois lettres. Cela permettra d'établir une comparaison précise et détaillée entre «A», «B» et «C». Il faut donner des notes aux différences entre «A» et «B» et entre «A» et «C». Les séquences audio dureront en général de 10 à 25 s et seront répétées autant de fois que vous le voudrez. Pour l'entraînement, vous êtes libres d'utiliser les haut-parleurs, les casques ou les deux. Vous disposez de trois heures pour vous entraîner sur tous les éléments que vous noterez réellement dans l'après-midi au cours de la phase de notation en aveugle.

Au cours des essais de l'après-midi, on vous demandera de noter les présentations selon l'échelle du Tableau 2:

TABLEAU 2

Dégradation	Note
Imperceptible	5,0
Perceptible mais non gênant	4,0
Légèrement gênant	3,0
Gênant	2,0
Très gênant	1,0

Il faut expliquer au participant la signification de cette échelle et insister sur le fait qu'elle doit être considérée comme une échelle continue à échelons égaux avec des repères définis pour des valeurs spécifiques.

Comme chaque essai de l'après-midi comprend une référence dissimulée (c'est-à-dire une répétition exacte de la référence), il serait normal qu'il y ait pour chaque essai au moins une note 5,0 (mais une seulement (voir la Note 1)). Si vous trouvez que «B» ou «C» est meilleur que la référence, cela veut dire que vous trouvez une différence «perceptible mais non gênante» et vous attribuerez une note comprise entre 4,0 et 4,9 selon la différence décelée.

Bien que vous soyez obligé de vous interroger, au cours de la phase d'entraînement, sur la façon dont vous interprétez personnellement les dégradations audibles, à l'aide de l'échelle de notation, il est important que vous ne discutiez jamais de votre interprétation personnelle avec les autres participants.

NOTE 1 – L'objectif du changement recommandé est de forcer le participant à «mieux deviner» le matériel codé parmi les stimulus. Nous estimons que certains participants sont en fait capables de détecter des défauts très faibles, mais par prudence, ils donneront deux notes de 5,0 plutôt que prendre position. Le changement recommandé permettrait de résoudre ce problème.

2 Exemple de contenu d'une séance de formation

La formation principale, d'une durée de 3 h, doit être effectuée avec des groupes de quatre participants environ dans la matinée du premier jour. Les participants auront dû recevoir au préalable des instructions écrites.

La séance de formation doit comprendre les éléments suivants:

- brève introduction des raisons et des objectifs de l'essai,
- passage répété des extraits choisis pour l'essai pour se familiariser avec la présentation sonore et avec les éléments de programme à évaluer ultérieurement,
- brève explication des systèmes à l'essai et du type de dégradation et présentation orale des catégories de dégradation fixées par le groupe de présélection,
- démonstration des dégradations au moyen des éléments comportant les dégradations les plus importantes,
- explication de la caractéristique à évaluer,
- explication de l'échelle de dégradation à cinq notes,
- entraînement à la commutation et à la notation.

Les jours d'essai suivants, il convient de rappeler aux participants les points traités pendant la principale séance de formation, ce qui peut comprendre à nouveau l'écoute des éléments pour l'essai, avant de procéder aux essais formels.

3 Phase de notation en aveugle

L'essai en aveugle a pour but la notation des divers éléments audio entendus le matin au cours de la phase d'entraînement.

A chaque essai, vous entendrez trois versions d'un élément audio donné. Elles seront appelées «A», «B» et «C» sur l'écran de contrôle vidéo. «A» est toujours la version de référence (*originale*) avec laquelle «B» et «C» seront comparés et notés. L'une d'elles, «B» ou «C», est une version modifiée et l'autre la référence dissimulée (identique à la référence). On ne vous dit pas laquelle de «B» ou «C» est la version modifiée et laquelle est la référence dissimulée, d'où le terme «aveugle» pour cette phase de notation. A tout moment, vous pourrez passer librement à «A», «B» ou «C». On peut répéter les séquences audio jusqu'à ce que vous soyez sûrs de votre évaluation. Vous pouvez à volonté passer à l'essai suivant quand vous êtes satisfaits de votre évaluation d'un essai.

Pour chaque essai, on vous demande de noter la différence éventuelle que vous remarquez entre «B» et «A», d'une part, et entre «C» et «A», d'autre part, au moyen de l'échelle à cinq notes du Tableau 3. Il faut donc donner deux notes pour chaque essai, une pour «B» et une pour «C». Il doit y avoir au moins une note 5,0 (mais une seulement (voir la Note 1 du § 1 du présent Appendice)) à chaque essai. Veuillez introduire vos notes dans l'ordinateur à la fin de chaque essai.

On peut aussi utiliser une fiche de notation au lieu d'introduire les notes dans un ordinateur.

Le Tableau 3 sera alors montré au participant et une copie sera disponible tout au long des séances de notation en aveugle.

Il faut expliquer au participant la signification de cette échelle et insister sur le fait qu'elle doit être considérée comme une échelle continue à échelons égaux avec des repères définis pour des valeurs spécifiques.

TABLEAU 3

Dégradation	Note
Imperceptible	5,0
Perceptible mais non gênant	4,0
Légèrement gênant	3,0
Gênant	2,0
Très gênant	1,0

APPENDICE 4

DE L'ANNEXE 1

Evaluation subjective: glossaire

Pour plus de clarté, on définit ici différents termes employés dans la présente Recommandation. La Fig. 9 illustre des correspondances entre certains de ces termes.

Caractéristique

Caractéristique perçue pour un événement auditif, conformément à une définition orale ou écrite.

Élément du programme

Extrait, traité par le système à l'essai.

Emplacement

Endroit où est effectué l'essai d'écoute. Il peut s'agir uniquement de l'emplacement géographique ou de la position du participant dans le local d'écoute. Peut être un des facteurs de l'essai.

Essai

Une partie de la séance qui va de la présentation d'un ensemble de stimulus à leur notation.

Essai doublement aveugle

Essai en aveugle où il n'y a aucune possibilité d'intervention non contrôlée entre l'expérimentateur et l'essai d'écoute.

Essai en aveugle

Essai où le participant ne dispose, à propos des essais, d'aucune autre information que les stimulus.

Extrait

Echantillon d'un passage de musique, de paroles ou autre convenant à l'évaluation des caractéristiques ou paramètres individuels de qualité sonore du système soumis aux essais.

Les extraits pour essai se présentent généralement sous forme d'enregistrements sonores (disque compact, R-DAT ou autres formats d'enregistrement ou de source).

Groupe d'écoute

Tout le groupe des participants qui fournissent les données d'un essai d'écoute.

Note

Expression numérique de la grandeur d'une caractéristique sur une échelle donnée.

Objet de l'essai

Système soumis aux essais, représenté par un certain nombre d'extraits que traite le système en question.

Participant

Personne qui évalue les stimulus d'un essai d'écoute.

Référence

Extrait pour essai, reproduit sans modification par l'objet de l'essai et servant de base de comparaison pour un essai avec dégradation.

Référence dissimulée

Référence non signalée au participant à l'essai.


Séance

Ensemble des essais qu'un participant ou un groupe d'écoute doivent évaluer au cours d'une période continue.

Stimulus

Combinaison d'un objet d'essai ou de la référence dissimulée ou de la référence et d'un extrait ou d'une portion d'extrait.

FIGURE 9
Illustration des correspondances entre certains termes du glossaire



Les deux essais représentés montrent les extrémités sur une gamme de dispositions possibles.