Sociologie

N° 2, vol. 9 | 2018

Théories et Méthodes

Échantillonner des populations rares

Une expérimentation du *Respondent Driven Sampling* en milieu musical*Sample rare populations. A Respondent Driven Sampling experimentation among musicians*

PIERRE BATAILLE, MARC PERRENOUD ET KAREN BRÄNDLE

Résumés

L'échantillonnage de populations dont il est impossible de connaître *a priori* les contours avec précision constitue un déficit majeur en sciences sociales. Certaines solutions ont néanmoins été proposées pour tenter de produire des données fiables dans ce type de cas. Parmi les procédures d'échantillonnage alternatives, c'est indubitablement la méthode du *Respondant Driven Sampling* (RDS) – « échantillonnage guidé par les répondants » –, apparue à la fin des années 1990 qui a connu la plus forte audience. L'ambition de cet article sera de présenter les points forts et les faiblesses de cette procédure, à travers un retour sur expérience dans le cadre d'une recherche sur des « musicien-ne-s ordinaires » suisses romand-e-s. Il s'agira premièrement de présenter l'outillage théorique, méthodologique et statistique qui structure cette procédure d'échantillonnage. Dans un deuxième temps, on montrera comment le RDS permet de construire des données originales et de qualité par rapport à d'autres procédures plus souvent utilisées – notamment l'enquête « en ligne » – pour des recherches sur des populations « rares ». Enfin, on reviendra sur les limites de l'échantillon recruté, du point de vue de la structuration du réseau complet des collaborations musicales sur une année de référence.

Sample rare populations. A Respondent Driven Sampling experimentation among musicians

Sampling populations without clear administrative boundaries is a major issue in social sciences. Some solutions have, however, been proposed in order to gather reliable data on this kind of populations. The Respondant Driven Sampling (RDS) undoubtedly figures as the most widespread of alternative sampling techniques. The main goal of this article is to discuss the strengths and the weaknesses of this procedure through our field work experience on Swiss "ordinary musicians." The theoretical, methodological and statistical tools involved in this kind of procedure will be presented first. Secondly, the article turns to discuss the originality and robustness of data gathered by the RDS method as compared with other more common procedure (like online surveys) in research on "rare" but not necessarily "hard to reach" populations. Finally, the article evaluates the limits of the sample by analysing the structuration of the whole network of musical collaborations.

Entrées d'index

Mots-clés : échantillonnage, réseaux, populations rares, musiciens, Suisse romande**Keywords** : Switzerland, sampling, network, rare populations, musicians

Texte intégral

- 1 L'échantillonnage de populations dont il est impossible de connaître *a priori* les contours avec précision constitue un défi majeur en sciences sociales. Ces populations « difficiles à atteindre » du fait de certaines de leurs caractéristiques potentiellement stigmatisantes (comme les usagers de drogues, les personnes LGBTQ...), ou plus simplement « rares » car trop spécifiques pour être saisies par les outils statistiques officiels sont en effet au cœur de nombreuses enquêtes. Les chercheur-e-s sont dans les faits bien souvent obligé-e-s de « bricoler » en croisant sources secondaires et données

de première main au risque d'abandonner tout espoir de voir leurs conclusions « prétendre à l'assise du raisonnement probabiliste » (Schiltz, 2005, p. 30).

- 2 Certaines solutions ont néanmoins été proposées pour tenter de produire des données fiables sur ce type de population dans le cadre d'un raisonnement inférentiel¹. Le champ de recherche autour des méthodes d'échantillonnage « adaptatives » (Thompson & Collins, 2002), où l'on découvre les contours de la population visée au cours du processus de recrutement des enquêté-e-s, a longtemps été relativement segmenté (Spreen, 1992). Les approches par dépistage de liens (*link tracing*), plus ou moins directement dérivées de l'échantillonnage par « boule de neige » (Goodman, 1961)², ont fait l'objet d'une attention particulière en comparaison d'autres propositions restées plus confidentielles, comme l'échantillonnage basé sur la proximité géographique ou la construction de cluster (Thompson & Collins, 2002). Parmi les méthodes utilisant le dépistage de liens, c'est indubitablement la méthode du *Respondent Driven Sampling* (RDS) – « échantillonnage guidé par les répondants » –, apparue à la fin des années 1990 (Heckathorn, 1997), qui a connu la plus forte audience. En 2013, on recensait ainsi dans la littérature disponible près de 460 recherches menées dans 69 pays ayant utilisé le procédé du RDS, la plupart du temps dans le cadre d'enquêtes menées en épidémiologie autour de problématiques de santé publique (White *et al.*, 2015).
- 3 Ce succès s'explique par la simplicité de la méthode mise en place par Douglas Heckathorn, mais également par la formalisation d'outils statistiques destinés à réduire les potentiels effets des biais de sélection sur les estimations de la structure de la population étudiée, alors que la plupart des autres méthodes d'échantillonnage par dépistage de liens ne permettent pas de prétendre à ce niveau de fiabilité (Van Meter, 1990). Les récents travaux menés sur les résultats obtenus par les méthodes d'estimations forgées par D. Heckathorn et ses collaborateurs montrent que ces estimations restent néanmoins bien souvent sujet à caution du fait des divers postulats sur lesquels elles reposent (Léon *et al.*, 2016).
- 4 L'objectif de cet article est double. À partir des résultats d'une recherche menée sur les musicien-ne-s « ordinaires » suisses romands³, il vise premièrement à montrer combien la méthode du RDS gagnerait à être plus largement diffusée chez les sociologues, tant elle permet de recueillir un matériau empirique original et riche sur des populations « rares », c'est-à-dire sous-représentées dans les enquêtes statistiques nationales mais pas nécessairement stigmatisées. À partir des données recueillies grâce à notre dispositif d'enquête original, il ambitionne également de proposer une évaluation de cette technique de recrutement. Alors que les travaux critiques quant aux résultats obtenus grâce au RDS sont souvent fondés sur des simulations informatiques, nos analyses permettent de donner une appréciation empirique des potentiels biais induits par ce processus d'échantillonnage.
- 5 Dans un premier temps, nous détaillerons les principales caractéristiques de la méthode du RDS. Ensuite, nous montrerons comment nous l'avons concrètement mise en place dans le cadre de notre recherche, en essayant de tenir compte des critiques déjà formulées dans d'autres travaux. Puis, nous comparerons les résultats obtenus *via* le RDS et les données récoltées sur la même population au moyen d'une technique d'échantillonnage plus souple. Enfin, nous analyserons la qualité du recrutement RDS à l'aune de la structuration de la population visée.

Le Respondent Driven Sampling : principes, limites et perspectives d'amélioration

Une méthode d'échantillonnage et d'estimation

- 6 La technique du RDS est basée sur une idée assez simple et bien connue depuis les travaux de Stuart Milgram sur le phénomène du « *small world* » (Milgram, 1967) : tous les individus d'un même groupe social sont liés entre eux par un nombre limité de liens⁴. Autrement dit, quel que soit le point de départ des chaînes de relations, on peut potentiellement atteindre n'importe quel individu du groupe en question au bout de x mises en relation successives.
- 7 Fort de ce constat, dans le premier article qu'il consacre au RDS en 1997, D. Heckathorn défend donc l'idée suivante : lorsque la sélection des informateurs et informatrices privilégié-e-s choisi-e-s pour nouer des contacts dans la population cible est non-aléatoire et arbitraire, si l'on multiplie les vagues de recrutement à partir de ce petit groupe initial, la sélection des personnes intégrées dans l'échantillon dépendra de

moins en moins des graines initiales et va tendre à devenir, tout de même, aléatoire. La méthode exposée dans cet article séminal et dans les principaux travaux qui ont été depuis consacrés à son développement (Gile & Handcock, 2010 ; Salganik & Heckathorn, 2004 ; Volz & Heckathorn, 2008 ; Wejnert, 2009) recouvrent en fait deux aspects bien distincts : la procédure de récolte concrète des données, d'une part ; les traitements statistiques particuliers à appliquer à ces données pour contrecarrer les biais de recrutement, d'autre part.

- 8 Concernant la procédure d'échantillonnage, le but du protocole RDS est de favoriser la multiplication des vagues de recrutement – puisque c'est cet encastrement des recrutements successifs qui est *in fine* la clé d'un échantillonnage le moins biaisé possible. Le protocole commence donc par la sélection d'un nombre (limité, généralement moins de dix) d'informateurs ou informatrices initiaux. Ces *primo* participant-e-s – appelé-e-s « graines » – doivent présenter des profils aussi variés que possible du point de vue des variables d'intérêts de l'enquête, de manière à diversifier les points d'entrée dans la population cible. Ces graines sont ensuite invitées à recruter deux ou trois de leurs contacts personnels correspondant aux critères de définition de la population. Pour ce faire, elles sont dotées de « coupons » que leurs contacts doivent retourner aux enquêteur-ice-s lors de leur interview – de manière à s'assurer qu'il y a bien eu un échange entre les individus recruteurs et les futurs recruté-e-s. Une autre recommandation pour s'assurer la participation active des recruteurs et recruteuses est de fournir une rétribution matérielle ou symbolique sous condition que les contacts participent effectivement à l'enquête et retournent les fameux « coupons » aux enquêt-eur-ice-s.
- 9 Le même procédé est répété à chaque vague avec les personnes nouvellement contactées, jusqu'à atteindre l'*equilibrium*, c'est à dire le stade où la structure globale de l'échantillon recruté se stabilise et ne varie plus d'une vague à l'autre sous l'angle des variables socio-démographiques classiques (âge, sexe, origine sociale, etc.) et des variables plus spécifiques à la population analysée. Cette procédure d'échantillonnage « dirigée par les répondants » fait le pari qu'en favorisant une implication des enquêt-e-s et la mobilisation de leurs réseaux personnels, on peut entretenir une dynamique de recrutement sur un nombre important de vagues.
- 10 Les expérimentations pratiques de ce protocole de recrutement et les problèmes rencontrés ont amené les chercheur-r-se-s investi-e-s dans ce champ à proposer un ensemble de techniques statistiques de pondération visant à limiter les effets des biais de sélection. Il ne s'agira pas ici de commenter dans le détail les formules derrière les estimateurs améliorés, fruits de ce travail de modélisation⁵, mais de présenter brièvement les principes sur lesquels se basent les outils statistiques propres au RDS et les problèmes qu'ils sont censés permettre de contourner. Nous aborderons la présentation de ces « estimateurs » dans la sous-partie suivante, portant sur les débats qui ont animé la communauté des chercheurs et chercheuses s'intéressant au RDS.

Une approche en débat

- 11 De manière très compréhensible, c'est la question du biais induit par les propriétés sociales particulières des personnes recruteuses qui est généralement vu comme le principal problème des échantillonnages de type RDS. Notamment, il est très vite apparu que, dans un processus de recrutement par l'intermédiaire de pairs, les individus ayant des réseaux personnels plus réduits (ceux et celles infecté-e-s à un stade relativement avancé du VIH dans une enquête sur les usag-er-ère-s de drogues injectables par exemple) ont potentiellement moins de chance d'être connectés à de potentiel-le-s recruteur-r-se-s – et ont donc moins de chances d'être recrutés.
- 12 Partant de cette idée, une première série d'estimateurs pondérés par la taille du réseau personnel des recruté-e-s dans la population cible a été proposée : les estimateurs dits « RDS I » (Salganik & Heckathorn, 2004) et « RDS II » (Volz & Heckathorn, 2008). L'estimateur RDS II pouvant être considéré comme une amélioration du premier, c'est celui qui est aujourd'hui le plus souvent utilisé. S'il permet théoriquement d'améliorer la qualité des estimations effectuées sur l'échantillon RDS, sa validité est fondée sur d'importants présupposés difficilement vérifiables la plupart du temps. L'estimateur RDS II est considéré logiquement comme valable si les six propriétés suivantes sont vérifiées :
 - 13 1. Le lien entre recruteur-r-se-s et recruté-e-s est réciproque (*i.e.* le réseau de recrutement n'est pas dirigé).
 - 14 2. Tous les individus de la population cible sont d'une manière ou d'une autre liés entre eux (*i.e.* le réseau que forme la population cible n'a qu'une seule composante).
 - 15 3. Le recrutement des répondant-e-s s'effectue avec remplacement (*i.e.* même une

fois interrogé-e-s, les enquêté-e-s peuvent être de nouveau désigné-e-s par les recruteur-r-se-s des vagues ultérieures).

16 4. Les personnes recrutées sont en mesure de reporter la taille exacte de leur réseau personnel au sein de la population cible.

17 5. Les personnes à qui sont transmis les coupons sont choisies aléatoirement dans l'ensemble du réseau des recruteur-r-se-s.

18 6. Chaque répondant-e ne peut recruter qu'une seule personne.

19 Bien entendu, dans une réelle procédure d'échantillonnage, il est quasiment impossible de respecter à la lettre ces règles. Aussi, différents travaux – essentiellement fondés sur des simulations informatiques utilisant des données issues du web – se sont attachés à tester la sensibilité de l'estimateur RDS II lorsqu'un ou plusieurs de ces postulats ne sont pas vérifiés. L'étude dirigée par Xin Lu comparant diverses simulations effectuées à partir des données d'un site web supportant un important réseau social destiné aux minorités sexuelles est sans doute la plus aboutie (Lu *et al.*, 2012). Elle a permis de montrer que les biais induits par le non-respect de ces différentes règles ne sont pas de même nature. Globalement, les biais apparaissent moins importants si la taille de l'échantillon représente une faible proportion de la population visée (moins de 50 %) et si cette population est faiblement clustérisée. Dans de telles conditions, le fait de recruter sans remplacements ne semble pas avoir de trop forte incidence notamment. En revanche, les biais sont très importants lorsque les liens unissant les recruté-e-s et recruteur-r-se-s ne sont pas réciproques et dans les cas où le choix des recruté-e-s au sein des réseaux personnels des recruteur-r-se-s est biaisé par des variables déterminantes dans la définition de la population cible. Par exemple, l'homophilie (très variable selon les pratiques sexuelles des enquêté-e-s) apparaît ici comme un facteur de biais non-négligeable pour les enquêtes portant sur la diffusion du VIH.

20 En dehors des biais induits par les choix des recruté-e-s, d'autres travaux récents ont montré que la taille de la population cible pouvait également induire des problèmes importants dans le calcul des estimations *via* l'estimateur RDS II (Gile & Handcock, 2010). À trop compenser la faible chance de recruter certaines catégories d'enquêté-e-s, l'estimateur RDS II en viendrait à surévaluer l'importance de sous-populations peu nombreuses – surtout dans les cas où la taille de l'échantillon représente plus de la moitié de la population cible. En introduisant une donnée sur la taille approximative de la population visée, Krista Gile (2011) a ainsi proposé un nouvel estimateur (*sequential sampling estimator* ou « RDS SS ») prenant en compte le fait que le processus d'échantillonnage se déroule au sein d'une population aux contours finis. Ce dernier estimateur présente l'avantage d'être relativement moins contraignant en termes de postulats de départ, en ne présupposant ni le recrutement avec remplacement ni le fait de ne recruter qu'une seule personne à la fois. Et surtout, là où pour avoir le plus de chances de s'avérer juste, le RDS II nécessitait de s'intéresser à une population de relativement grande taille, l'estimateur RDS SS permet d'envisager des estimations de qualité sur une petite population cible. En revanche, il nécessite d'avoir une idée – même vague – de la taille de la population visée, ce qui est strictement impossible dans certains cas⁶.

Un manque crucial d'expérimentations empiriques

21 Grâce à ces améliorations successives, les estimations obtenues sur des échantillons RDS ont significativement gagné en précision. Certains travaux récents fournissent par exemple des outils pour calculer la taille approximative de l'échantillon à recruter idéalement au regard de la structuration estimée de la population cible (Wejnert *et al.*, 2012). Néanmoins, l'une des principales faiblesses de l'outillage statistique construit autour de la procédure RDS est d'avoir été pensé à partir de simulations ou de données du web – et donc de manière relativement déconnectée des conditions concrètes d'enquête. Comme le souligne Matthew Salganik (2012), rares sont les enquêtes qui permettent de documenter sur la base d'observations de terrain le déroulement précis de la procédure d'échantillonnage et les potentiels biais qu'elle comporte, soit parce que nombre d'enquêtes se réclamant du RDS se contentent de suivre la description canonique de la procédure de recrutement sans produire d'analyse réflexive sur son déroulement ; soit parce qu'elles portent sur des réseaux déjà constitués (*via* Internet notamment) ; soit, enfin, parce qu'elles portent sur des populations et des sujets particulièrement sensibles – et qu'il est donc difficile de rendre publiques certaines informations sur la cuisine interne du plan d'échantillonnage. Les bases d'une réflexion plus systématique sur les implications et les difficultés d'une telle procédure d'échantillonnage « dans le monde [social] réel » font ainsi encore cruellement défaut

(Salganik, 2012).

- 22 Certaines recherches ont eu l'opportunité de pouvoir comparer les estimations calculées à partir d'une procédure RDS avec les proportions calculées à partir de la population réelle (McCreesh *et al.*, 2012, 2013). Elles montrent que l'échantillonnage RDS est fiable à condition de bien connaître les logiques structurant la population cible – et donc d'allier travail ethnographique et formalisation statistique. De tels croisements ont permis de formuler un ensemble de recommandations pratiques pour assurer un déroulement optimal du processus d'échantillonnage (Gile *et al.*, 2015 ; White *et al.*, 2015).
- 23 Néanmoins, ces tentatives de mise en perspective des résultats RDS dans le cadre d'enquêtes empiriques poussées sont relativement peu nombreuses. Et certains facteurs de biais de recrutement restent pour le moment assez mal connus. On sait notamment très peu de choses sur la manière dont se déploie la dynamique de recrutement à l'aune de la structuration du réseau complet de la population. On peut légitimement faire l'hypothèse que les personnes recrutées par les graines et les répondant-e-s tendent à occuper une place plus centrale dans le réseau complet que les personnes écartées par les recruteur-r-se-s, comme le laisse à penser certaines études montrant que la taille des réseaux personnels des enquêté-e-s diminue au fur et à mesure que les vagues de recrutement se succèdent (Johnston *et al.*, 2015). En effet, il est très probable que le recrutement des futurs enquêté-e-s soit informé par des logiques réputationnelles et tendent à s'orienter relativement naturellement vers certains individus particuliers du groupe social visé – soit parce qu'ils sont envisagés comme de « bons clients » dont la bonne volonté va faciliter la tâche des recruteur-r-se-s ; soit parce qu'ils sont perçus comme des cas potentiellement plus « intéressants » que certain-e-s act-eur-ice-s occupant des positions plus marginales. Mais il n'existe pour le moment aucune enquête qui permette de rendre compte précisément de l'ampleur de ce potentiel *biais de centralité*. En analysant comment se situent les personnes recrutées par RDS au sein du réseau complet reliant l'ensemble des membres d'une population particulière, c'est à ce débat que le présent article entend participer.
- 24 Parallèlement, il faut aussi relever que la fragilité de certains résultats établis *via* une procédure d'échantillonnage RDS vient du fait que les expérimentations de cette méthode ont principalement été pratiquées sur des terrains très peu accessibles par d'autres moyens – généralement des personnes en situation de grande précarité sociale/sanitaire ou appartenant à des groupes sociaux fortement stigmatisés –, sur lesquelles il est donc très difficile d'avoir un point de vue complémentaire à celui obtenu grâce au RDS. Le deuxième fil rouge de notre article sera de défendre l'idée que l'épistémologie du RDS gagnerait à être plus investie par les chercheurs et chercheuses en sciences sociales travaillant sur d'autres types de populations « rares » dans les enquêtes nationales, comme les « musicien-ne-s ordinaires » romand-e-s sur lequel-le-s nous avons enquêté.

Un *design* d'enquête « mixte » pour échantillonner des « musicien-ne-s ordinaires »

Contourner le double biais des enquêtes quantitatives sur les travailleurs et travailleuses artistiques

- 25 Avant de présenter plus précisément l'enquête dont sont issues les données analysées dans le cadre de cet article, il nous faut préciser que notre recherche n'est pas la première à tester une procédure de type RDS pour échantillonner des musicien-ne-s. L'une des enquêtes ayant le plus contribué à populariser la méthodologie RDS visait ainsi à mieux connaître les conditions de vie et les pratiques des musicien-ne-s de jazz étasunien-ne-s évoluant dans différentes aires urbaines du pays (Heckathorn & Jeffri, 2001). Si le RDS est intéressant dans pareil cas, c'est qu'il permet, comme nous allons le voir, de s'affranchir de deux biais – « économiste » et « légitimiste » – qui guettent la plupart des enquêtes quantitatives sur les travailleur-r-se-s artistiques. Sans prétendre à l'exhaustivité, nous voudrions présenter, à travers quelques exemples, les traditionnels obstacles auxquels se heurtent ces recherches afin d'expliciter comment la méthodologie présentée ici peut permettre de relever les défis qu'un tel échantillonnage représente.

- 26 Parce qu'il n'existe pas de consensus sur ce qu'« être artiste » veut dire, dessiner les contours d'une population de travailleur-s-e-s artistiques en vue d'un échantillonnage est une opération de recherche à part entière (Menger, 2010). Mais surtout, dans pareil cas, la difficulté principale – corrélative à la précédente – est la rareté des bases de données assez complètes pour permettre de faire un choix de délimitation de la population cible en pleine connaissance de cause. De fait, les enquêtes quantitatives sur les artistes sont bien souvent contraintes d'utiliser des bases de données construites à des fins non-scientifiques (administration, promotion, etc.) (Mc Pherson, 2001) et prêtent le flanc à deux types de critiques.
- 27 L'utilisation de registres administratifs – comme un registre de cotisation à une caisse d'indemnité par exemple (Coulangeon, 2004 ; Vessillier, 1989) – et, plus généralement, de données relatives à l'activité économique découlant de la production artistique, peut constituer une possible stratégie d'échantillonnage. Elle présente l'inconvénient de réduire l'activité artistique aux entrées d'argent qu'elle génère, faisant fi du fait que nombre de travailleur-s-e-s artistiques, surtout lorsqu'il-le-s occupent les niveaux inférieurs de la hiérarchie professionnelle, ont « une double vie » pour assurer leur subsistance (Lahire, 2006). Elle peut surtout avoir tendance à sous estimer la dimension symbolique que peut recouvrir l'exercice d'une activité comme l'écriture, la musique, etc. Elle tend par là même à minimiser l'impact de la reconnaissance de cette activité par les pairs, les critiques, les programmeurs, également fondamentale quant à la stabilisation professionnelle dans les mondes de l'art.
- 28 Prenant acte de cette limitation, une autre stratégie d'échantillonnage consiste à s'intéresser aux personnes reconnues comme faisant partie intégrante de l'espace professionnel parce qu'elles ont gagné des prix (Dubois & François, 2013), parce qu'elles ont été programmées dans des espaces de diffusion (Giuffrè, 1999) ou encore parce qu'elles ont été reconnues *a posteriori* comme membres à part entière de la communauté artistique de leur temps (Accominotti, 2009) pour ne citer que quelques travaux. Il s'agit dans ce cas de s'intéresser aux personnes consacrées comme « artistes » par certaines institutions culturelles, sans références à la composition effective de leurs revenus. Si cette deuxième stratégie intègre le fait que l'espace des professions artistiques est régi par des logiques qui lui sont propres – en dehors de toute référence au revenu qu'elle génère –, elle laisse néanmoins sur le bord du chemin l'écrasante majorité des personnes qui pratiquent une telle activité mais gravitent loin des pôles de consécration.
- 29 Pour résumer, ces deux stratégies d'échantillonnage courent le risque d'importer dans la définition de la population des éléments étrangers à sa constitution (biais d'une vision strictement « économiste ») ou de laisser dans l'ombre la large proportion des travailleur-s-e-s artistiques qui n'accèdent pas aux instances de consécration (biais d'une définition trop « légitimiste » de la population visée). Pour le cas des musicien-ne-s, ce sont peut-être les enquêtes ethnographiques (Becker, 1985 ; Grazian, 2004 ; Buscatto 2007 ; Perrenoud, 2007) qui ont pointé avec le plus d'acuité ces deux limites, en montrant que le fait de se reconnaître et d'être reconnu-e comme « musicien.ne » ne se résumait pas à une question de revenu ou de certification par quelque instance de légitimité. Ces recherches montrent en effet qu'« être musicien.ne », surtout lorsqu'on se situe aux niveaux intermédiaires et inférieurs de la hiérarchie professionnelle, découle d'avantage d'une somme de micro interactions avec les pairs, le public, les employeur-s-e-s potentiel-le-s (patron-ne-s de bar, salles de concert, responsables de l'animation d'une réception, etc.) ou encore l'administration. Reste que ce type de critères d'inclusion est, on le comprend, difficilement opérationnalisable dans le cadre d'une procédure d'échantillonnage classique en vue d'une enquête quantitative.

Procédure(s) d'enquête(s)

Partir d'une définition indigène

- 30 Dans le cadre de notre recherche sur les musicien-ne-s « ordinaires » en Suisse romande – c'est-à-dire ceux et celles, ni riches ni célèbres, qui vivent ou essaient de vivre de leur pratique musicale –, la prise en compte des différentes limites des enquêtes quantitatives sur les travailleurs et travailleuses artistiques nous a donc orientés vers l'utilisation de techniques d'échantillonnage alternatives – et en premier lieu, le RDS. Il faut par ailleurs ajouter que notre recherche s'inscrivant dans le cadre d'un État (la Confédération helvétique) qui ne se distingue pas par ses « grands gestes de politique culturelle » (Moeschler, 2011, p.15) – et qui produit donc peu de

statistiques à ce sujet-, il nous était impossible d'utiliser une base de données préexistante.

- 31 S'il permet de garder la main sur les critères de délimitation de la population, le choix d'une telle procédure d'échantillonnage nécessite néanmoins d'opter pour une définition *a priori* de la population ciblée. Partant des analyses développées dans les travaux américains et français déjà cités et des observations menées au cours d'une enquête ethnographique sur les musicien-ne-s de musique actuelles évoluant principalement dans l'espace suisse francophone (Perrenoud & Chapuis, 2016 ; Perrenoud & Leresche, 2016), il nous est ainsi apparu que ce qui définissait une personne comme membre à part entière du groupe des « musicien-ne-s » pour les premier-e-s intéressé-e-s, c'était -très simplement- sa désignation par les autres membres du groupe comme un pair, matérialisée par le fait d'avoir joué ensemble dans les mêmes projets musicaux (groupe, *backing band*, session de studio, création pour le spectacle vivant, etc.). Aussi, après avoir testé d'autres types de définitions basées sur le nombre de représentations en public contre rémunération notamment, nous avons retenu comme critère d'inclusion minimum le fait d'avoir collaboré au sein d'un même projet musical l'année précédent l'enquête, car c'était celui qui semblait avoir le plus de sens pour les personnes rencontrées dans le cadre de notre enquête ethnographique. Dans l'objectif d'un échantillonnage RDS, demander aux interviewé-e-s de recruter trois personnes avec lesquelles elles avaient collaboré récemment avait aussi l'avantage de garantir la réciprocité des liens : en effet, ce critère d'inclusion permettait de baser le recrutement sur un événement qui ne dépendait pas de la subjectivité des personnes recruteuses quant au sens de leurs relations avec les personnes potentiellement recrutées -et donc garantissait une symétrie de la relation recruteur.e/se/recruté-e, soit l'un des postulats important sur lesquels sont basés les outils statistiques RDS.

Le choix des graines

- 32 Pour nos graines (N = 7), nous avons apporté une attention particulière à réunir une palette de profils professionnels et sociologiques aussi variés que possible. À partir des résultats de notre enquête ethnographique et d'une autre enquête menée dans une perspective proche en France (Perrenoud, 2007), nous avons jugé que le style de musique n'était pas une variable pertinente. En effet, saisi à travers des étiquettes aussi vagues que jouer du « jazz » ou du « rock », le style pratiqué peut recouvrir des réalités sociales, économiques et esthétiques très différentes, voire opposées (Perrenoud, 2006 ; Picaud, 2015). Le type de répertoire (soit le fait de jouer des compositions originales ou seulement des reprises) et le type de dispositif de jeu le plus souvent pratiqués ont ainsi été privilégiés. Par « type de dispositif de jeu » nous entendons distinguer ici, dans la lignée des travaux précités (Perrenoud, 2006), le fait de jouer dans le cadre d'un concert (avec une scène, des *backstages*, face à un public venu expressément écouter de la musique), dans le cadre de l'animation anonyme d'un événement non-musical (une inauguration, un comité d'entreprise... soit des situations où la production de musique est avant tout une prestation de service) ou -intermédiaire entre ces deux extrêmes- dans le cadre d'une situation d'*entertainment* (typiquement, une prestation dans un bar, où la production de musique *live* est certes l'occasion de vendre des boissons pour le ou la tenancière, mais va aussi intéresser le public suivant son affluence et sa réceptivité). Conjointement à ces différents critères, d'autres variables socio-démographiques telles que l'âge, la localisation géographique de l'activité ou encore le sexe ont été prises en compte. Au final, nos graines couvrent une large diversité de situations, allant du pianiste habitué des festivals internationaux au chanteur de *doo-wop* spécialisé dans l'animation de banquet et de séminaires en passant par le jeune percussionniste fraîchement diplômé et essayant de faire sa place en multipliant les projets ou la violoniste expérimentale, partageant son temps entre performances d'improvisation radicale et production de documentaires télévisuels.

Récolter des réseaux complets

- 33 Conscients de certaines limites de la procédure RDS classique -notamment celles relatives à l'arbitraire dans le tri des personnes recrutées- nous avons décidé d'intégrer certaines innovations qui nous permettaient de contrôler les ressorts sociaux du choix des personnes à interroger parmi les réseaux des personnes recruteuses.
- 34 Dans un premier temps, nous avons lancé une enquête par Internet à partir des mêmes graines utilisées par la suite pour le RDS, mais en demandant aux personnes répondantes de donner le nom et le contact de la totalité des individus avec lesquels

elles avaient collaboré durant l'année précédant l'enquête. Une invitation à répondre à cette enquête en ligne était par la suite envoyée à chacune des personnes citées, de façon à essayer de dessiner le réseau le plus complet possible des collaborations musicales liant entre eux et elles les musicien-ne-s romand-e-s. Notre idée initiale était de relancer une enquête par RDS en partant des mêmes graines pour mieux comprendre comment s'opérait le choix des personnes recrutées *via* RDS à l'aune de la structure du réseau complet. Malheureusement, cette première enquête s'est essoufflée après trois vagues du fait du très faible taux de réponse et de la relative réticence des personnes enquêtées à nous communiquer toutes les informations nécessaires pour contacter ceux et celles avec qui elles avaient collaboré, malgré nos tentatives pour les rassurer au sujet de l'anonymisation des données. Les données récoltées dans cette première enquête nous ont néanmoins permis de disposer d'un point de comparaison avec les données RDS pour analyser la performance relative de ce dispositif particulier par rapport à une procédure d'échantillonnage par interrelations non contrôlé.

35 Malgré cet échec initial, nous avons néanmoins décidé de lancer une procédure d'échantillonnage RDS à partir des mêmes graines (à l'exception de deux personnes qui ont été remplacées) dans un deuxième temps. Par rapport à la procédure RDS classique, nous avons introduit deux modifications. Tout d'abord, nous n'avons proposé aucun *incentive* matériel, comme cela est préconisé généralement dans le but de stimuler une participation active de la part des personnes recrutées. Dans le contexte suisse, où les standards de vie (salaire, coût de la nourriture, de la santé...) sont relativement élevés, il nous est paru peu pertinent et potentiellement très onéreux de promettre une rétribution à la hauteur d'une heure de salaire moyen – tel que cela est souvent conseillé (Tyldum *et al.*, 2014). Nous avons préféré mettre en avant auprès des enquêté-e-s les gains potentiels de notre recherche pour les personnes évoluant dans leur espace professionnel, en précisant qu'elle permettrait, grâce à une participation importante, de mieux comprendre l'activité musicale et les parcours de vie des musicien-ne-s en Suisse et de mieux saisir les enjeux auxquels ils et elles font face quotidiennement.

36 Ensuite, dans l'objectif de reconstruire un réseau aussi complet que possible des collaborations entre musicien-ne-s romand-e-s, nous avons intégré une question invitant les personnes recrutées à lister les noms de ceux et celles avec qui elles avaient collaboré l'année précédant l'enquête – en demandant également des indications sur le lieu de résidence de ces collaborat-eur-ice-s, afin de mesurer l'étendue de ces réseaux individuels. Comme nous le verrons plus en détail dans la partie suivante, malgré cette dernière question relativement intrusive, le processus de recrutement a pu être maintenu sur huit vagues, nous donnant *in fine* un échantillon de 130 individus dont sept graines.

37 Il faut ici insister sur le fait qu'une telle innovation par rapport à la procédure RDS standard a été possible du fait que notre population cible n'était pas l'objet de stigmatisation particulière. On comprend bien que dans le cas des populations les plus souvent visées par les enquêtes RDS (migrant-e-s en situation illégale, usager-ère-s de drogues, etc.), le fait de nommer des personnes appartenant à la catégorie visée en établissant des listes nominatives peut potentiellement participer à mettre ces dernières en danger. Dans notre cas, même si la question restait un moment délicat de l'interview, elle a pu rencontrer un accueil généralement favorable – et cela, sans que nous ayons l'impression de contrevenir à des principes éthiques fondamentaux. D'autant plus que, pour un-e musicien.ne, égrainer ses collaborations peut être vu comme valorisant : une liste fournie de collaborateurs et collaboratrices revient en effet à afficher une bonne insertion professionnelle et une bonne reconnaissance par les pairs de son savoir-faire musical. On trouve ici un premier exemple de ce que permet l'expérimentation d'une procédure RDS auprès d'une population généralement « rare » dans les bases de données officielles. Cette question nous a permis de reconstruire un réseau de collaboration entre 1 166 musicien-ne-s, identifiables de manière unique (puisque nous disposons des noms/prénoms/surnoms/noms de scène et que le nombre d'homonyme s'est avéré très réduit⁷).

38 Précisons également que les moyens à mobiliser pour mener ce type de méthodologie sont relativement raisonnables. Ainsi la mise en place des différentes enquêtes présentées ici a pu être réalisée grâce à un intense travail d'équipe, mobilisant cependant un groupe limité de chercheur-r-se-s. L'enquête ethnographique a été menée par trois personnes sur une période de deux ans. La conceptualisation du questionnaire et du processus d'échantillonnage a mobilisé toute notre équipe (sept personnes, dont un chercheur statutaire, deux doctorant-e-s et quatre étudiant-e-s de Master) pendant une année⁸. La passation à proprement parler du questionnaire RDS et le codage ont quant à eux été effectués à 70 % par deux d'entre nous sur une période de dix mois, les

enquête-e-s restant ayant été interviewés par les autres membres de l'équipe.

De l'efficacité du RDS

Des modes de diffusion différents au sein de la population cible

39 Dans cette première sous-partie, nous allons analyser les différences entre l'échantillon recruté par l'enquête web et celui recruté par l'enquête RDS en termes de diffusion et de qualité de recrutement. Les Figures 1 et 2 représentent les arbres de diffusion des invitations à participer au questionnaire (pour l'enquête web) et des recrutements (pour l'enquête RDS) en faisant apparaître le statut des différentes personnes approchées : les graines ; les répondant-e-s ; les répondant-e-s ; les personnes contactées mais n'ayant donné aucune réponse ; les doublons ; et enfin, les personnes ayant explicitement refusé de nous répondre⁹.

Figure 1. Diffusion de l'enquête web

Figure 2. Diffusion de l'enquête RDS

Lecture : Les différents arbres de recrutement figurés ici représentent la diffusion de notre questionnaire web (Figure 1) et de notre enquête RDS (Figure 2). Les points de départ de chaque arbre sont les graines. Les nœuds du graphe représentent tous une personne ayant été contactée dans le cadre de l'une ou l'autre des enquêtes. Chaque embranchement de ces arbres est le début d'une nouvelle vague de recrutement.

40 Comme cela apparaît dans la Figure 1, si elle a pu rencontrer un relatif succès dans un premier temps - avec un taux de réponse d'environ 30 % pour les requêtes envoyées en première vague - l'enquête web s'est néanmoins très rarement diffusée au-delà de deux vagues. Par ailleurs, lorsque le processus de recrutement s'est développé jusqu'à atteindre une troisième vague, on peut noter que la proportion de « doublons » est particulièrement élevée parmi les personnes contactées à ce stade du recrutement. Cette dernière observation laisse à penser que, lorsqu'elle a perduré au-delà de la deuxième vague, la diffusion de l'enquête web s'est opérée principalement au sein d'un sous-groupe relativement hermétique de musicien-ne-s et a eu du mal à dépasser les frontières des réseaux de connaissance relativement proches de nos graines.

41 On peut également noter que, lors de l'enquête web, deux graines n'ont finalement

pas transmis toutes les informations nécessaires pour pouvoir contacter leurs éventuels collaborateurs ou collaboratrices – et ce, malgré nos relances multiples. Ces deux graines « stériles » sont celles qui ont été remplacées dans l'échantillonnage RDS. Par rapport aux autres graines, ces deux personnes présentent des caractéristiques bien particulières : il s'agissait de deux musiciens (hommes) dont l'activité musicale principale consistait à jouer dans des dispositifs d'animation un répertoire essentiellement (si ce n'est uniquement) formé de reprises. Différentes hypothèses peuvent expliquer ce refus.

42 Tout d'abord, les échanges informels avec les deux enquêtés ont fait ressortir que, pour eux, les questions relatives aux déclarations concernant leurs revenus étaient particulièrement sensibles. Du fait de la concentration de leurs activités sur des engagements à court terme dans le cadre d'animations, ils sont amenés à gérer très souvent des échanges de petites sommes d'argent – parfois de la main à la main et pas nécessairement déclarées. Ils ont ainsi exprimé plusieurs fois leurs craintes

43 quant à apparaître dans une base de données informatisée et leur réticence corrélative à encourager leurs collaborateurs et collaboratrices à le faire.

44 Par ailleurs, notre premier échec auprès de ce sous-groupe particulier des musicien-ne-s plus « animateurs » qu'« artistes créateurs » s'explique également par leur profil sociologique. Comme une analyse plus fouillée de nos résultats d'enquête le montre très clairement (Perrenoud & Bataille, 2017), les musicien-ne-s correspondant à ce type de profil professionnel comptent parmi les moins diplômé-e-s des individus de la population ciblée par l'enquête. Dans la mesure où participer à une enquête web auto-administrée comme celle que nous avons conçue présuppose une certaine bonne volonté de la part des participant-e-s pour se conformer à des consignes relativement strictes et accepter de rester un long moment (presque une heure suivant la taille du réseau personnel et la complexité du parcours) devant son clavier et son écran, les difficultés rencontrées auprès de ce sous-groupe des « musicien-ne-s d'animation » peut également être interprété comme un signe de leur relative distance à la culture scolaire – par laquelle peuvent s'acquérir le type de dispositions nécessaires au renseignement en bonne et due forme de notre questionnaire.

45 En comparaison, la diffusion de l'enquête RDS (Figure 2) s'est maintenue en moyenne plus longtemps (trois vagues pour les plus petites chaînes et huit pour la plus longue). Malgré son caractère parfois contraignant, la procédure RDS a fait ainsi preuve d'une meilleure efficacité de recrutement dans le temps. La rencontre en face-à-face des personnes recrutées et la relation de confiance qui se noue au moment de l'entretien garantissent indubitablement de bien meilleures conditions pour multiplier les vagues et, par là même, garantissent une augmentation des chances de recruter des personnes déconnectées des graines sélectionnées arbitrairement. Les quelques refus de participer et les défections malgré nos relances n'ont ici pas entravé la marche de l'enquête.

Une réponse aux limites des enquêtes par internet

46 La comparaison de la composition des deux échantillons (web et RDS) sous l'angle de différentes variables permet également de se faire une idée de la qualité du recrutement opéré grâce à ces deux méthodes (Tableau 1). Par ailleurs, pour tester la robustesse des estimations obtenues à partir de l'échantillon RDS, en plus des proportions calculées sur l'échantillon web et celles obtenues sans redressement sur l'échantillon RDS (dites estimations « naïves »), nous avons fait figurer les valeurs des proportions calculées grâce aux estimateurs RDS II et RDS SS.

47 Pour mener cette comparaison, nous avons sélectionné un ensemble de caractéristiques qu'il nous semblait important de voir bien représentées dans notre échantillon au vu de notre objectif initial. Nous avons donc retenu des variables telles que le sexe, le dernier diplôme obtenu, l'origine sociale, le pays de naissance et le lieu de résidence au moment de l'enquête. Nous avons également sélectionné certaines variables relatives à la pratique professionnelle musicale, à savoir la part du revenu mensuel que représentait en moyenne le revenu musical au cours de l'année précédent l'enquête, le fait de s'être produit à l'étranger depuis trois ans et le fait d'avoir déjà décroché au cours de sa carrière une subvention d'une fondation privée. Dans un système où le financement de la production musicale se fait en partie sur la base de l'inscription géographique dans une commune ou un canton particulier (OFS, 2010 ; Perrenoud, 2013), le fait de se voir attribuer un subside par l'une des nombreuses fondations privées – la plupart du temps sur la base du dépôt d'un projet et de l'examen par une commission statuant sur sa qualité – apparaît en effet comme un indicateur pertinent de légitimité culturelle relative. Enfin, une variable sur le type de formation

musicale suivie a également été introduite dans cette analyse comparative.

- 48 Par facilité de présentation, seule la modalité la plus pertinente des variables sélectionnées a été présentée, soit, respectivement, être une femme, avoir décroché un diplôme du supérieur, avoir un père ayant appartenu aux classes populaires, être de nationalité suisse ou habiter dans une capitale de canton pour les variables socio-démographiques ; avoir un revenu musical mensuel supérieur à 4 000 CHF (3 741 euros, ce qui reste relativement modeste pour la Suisse¹⁰), s'être uniquement produit en Suisse au cours des trois dernières années et avoir reçu une subvention d'une fondation privée au cours de sa carrière pour les variables relatives à la pratique professionnelle ; et, concernant la formation musicale, nous avons dichotomisé la variable.

Tableau 1. Structuration des échantillons web et RDS

% de répondant-e-s qui...	Web	RDS naïve	RDS II	RDS SS
...sont des femmes	31	23	18	19
...sont diplômé-e-s du supérieur	71	60	60	60
...ont un père ayant appartenu aux classes populaires	12	23	19	19
...sont de nationalité suisse	86	84	82	82
...ont un revenu musical > CH 4000.-	29	32	41	41
...résident dans une capitale cantonale	69	45	53	52
...se sont produit-e-s uniquement en Suisse	23	14	19	18
...ont reçu une subvention privée	73	55	50	50
...sont diplômé-e-s d'une école de musique	54	63	63	62
TOTAL (N)	35	123	123	123

Lecture : Chez les individus recrutés via l'enquête web, 71 % ont décroché un diplôme de l'enseignement supérieur.

- 49 L'analyse des différences observées entre les estimations obtenues sur l'échantillon web et les estimations RDS permet de souligner le gain de qualité obtenu grâce à la procédure RDS. Parmi les variables sélectionnées, l'origine géographique, le lieu de résidence, le fait d'avoir reçu une subvention d'une fondation privée et la formation musicale distinguent le plus fortement nos enquêté-e-s web de nos enquêté-e-s RDS (entre 10 et 20 points d'écart). Les répondant-e-s web sont ainsi plus souvent des femmes, sont plus souvent diplômé-e-s du supérieur et sont moins souvent originaires de milieux populaires. Ils et elles habitent plus souvent dans des capitales cantonales, ont plus souvent eu une subvention d'une fondation privée et sont plus souvent passé-e-s par une école de musique professionnelle (conservatoire ou autre). Pour le dire vite, il apparaît ici que les franges les plus dotées en capitaux scolaires et symboliques de la population cible sont surreprésentées parmi les répondant-e-s à l'enquête web. Si ce biais des enquêtes par internet est bien connu et documenté (Bethlehem, 2010), nos résultats montrent que l'échantillonnage par RDS peut être une alternative efficace et de qualité quand, dans les cas comme le nôtre, la population visée n'apparaît dans aucun registre préexistant. Sans nécessairement annuler tous les biais de sélection, il apparaît ici que le RDS permet d'atteindre des membres de la population cible qui, de par leurs propriétés sociales, sont généralement hors d'atteinte des enquêtes web.

- 50 Les résultats présentés dans le Tableau 1 permettent également de comparer les proportions obtenues grâce aux différents estimateurs RDS. Dans la quasi totalité des cas, les estimateurs RDS II et RDS SS tendent à agrandir l'écart déjà observé entre la simple comparaison des estimations RDS naïves et les proportions calculée à partir de l'échantillon web. Mais surtout, il est frappant de remarquer que les proportions obtenues avec les deux estimateurs convergent et sont quasiment identiques dans tous les cas.

- 51 Les simulations menées par K. Gile montrent que lorsque certains des six postulats ne sont pas respectés, les résultats obtenus avec les estimateurs RDS II et RDS SS sont très différents, du fait que l'estimateur RDS II tend à surestimer la présence de certaines sous-populations (Gile, 2011 ; Gile & Handcock, 2010). À la lumière de cette remarque, le fait que nous n'observions aucune différence notable entre les deux estimations semblerait indiquer que les conditions sont réunies pour produire des estimations de qualité grâce à l'outillage statistique RDS. Cette remarque renvoie à notre sens au fait que les chances de recrutement de la plupart des sous-catégories de

population qui nous intéressent ici sont assez importantes pour que l'estimateur RDS II n'amène pas à les surreprésenter. Et nos résultats suggèrent que dans le cas d'une enquête sur une population peu présente dans les enquêtes nationales et pas nécessairement « difficile à atteindre », la procédure RDS et les outils qui y sont associés paraissent particulièrement adaptés pour produire des données quantitatives de qualité.

Un recrutement plus central

- 52 Le dispositif de recueil de données mis en place a permis de reconstruire le réseau des « collaborations » de nos enquêté-e-s l'année précédant l'enquête. Pour les analyses développées ici, nous avons raisonné à partir des individus qui sont au moins deux fois nommés comme ex-collaborateurs ou ex-collaboratrices ($n = 384$). La Figure 3 représente ce réseau de collaborations.

Figure 3. Le réseau des collaborations (2013)

Lecture : Dans ce graphe, chaque lien représente une collaboration musicale entre deux personnes. La taille des nœuds est proportionnelle à leur nombre de sommets. Outre les personnes interviewées dans le cadre de notre enquête, ne sont figurés ici que les individus apparaissant au moins deux fois dans la liste des collaborations recueillies.

- 53 La première chose que l'on peut relever, c'est que le réseau obtenu est à une seule composante. Cela peut en partie expliquer les bons résultats obtenus grâce à l'estimateur RDS II, particulièrement sensible à l'homophilie et à la clusterisation qui en découle bien souvent. À un niveau plus sociologique, ce premier résultat de l'analyse réseau indique que, chez les musicien-ne-s ordinaires, la multiplication des collaborations au-delà des frontières stylistiques *a priori* (rock/jazz, etc.) est très courante : en effet, en partant de profil socio-esthétiques radicalement opposés (voir la présentation succincte de nos graines) on arrive néanmoins à trouver des chemins qui lient entre elles toutes les personnes de la population cible. Le réseau dessine ici un espace professionnel commun à tous les musiciens et musiciennes non-classiques, qu'il s'agirait d'analyser comme tel, en dépassant donc le parti pris socio-esthétique de nombreux travaux sur les professionnel-le-s des musiques « actuelles ».
- 54 Sur la Figure 3, la taille des nœuds du réseau (triangles ou carrés) est proportionnelle à leur nombre de sommets, c'est à dire à la centralité de degré de ces nœuds. Il apparaît ici que la plupart des graines (surtout celles situées au nord du graphe) sont bien plus « centrales » que les autres personnes sous cet angle. Il apparaît également intuitivement que, conformément à ce que l'on pouvait attendre, les personnes interviewées dans le cadre de notre enquête ont des scores de centralité de degré relativement plus élevés que les personnes non-interviewées.
- 55 La Figure 4 permet de comparer plus précisément les différences de centralités des

nœuds, à l'aune de trois indicateurs de centralités reflétant trois aspects du caractère plus ou moins « central » des personnes étudiées : la centralité de degré qui est proportionnelle au nombre de degré des nœuds (dans notre cas, le nombre de fois où la personne est citée comme collaboratrice par une autre personne du réseau) ; l'intermédiarité, qui renseigne sur le fait que le nœud concerné est souvent au croisement des chemins les plus courts entre deux autres nœuds ; et enfin, la mesure de la centralité de vecteur propre, qui exprime la plus ou moins grande proximité entre le nœud à l'étude et les nœuds les plus connectés du graphes.

Figure 4. Dispersion des indices de centralité des noeuds en fonction de leur statut

Lecture : Pour les personnes interviewées, la médiane de la valeur normalisée de l'indice d'intermédiarité est de 6,5. Les points représentent les valeurs trop extrêmes pour être représentative de la distribution.

NB : L'analyse de variance (ANOVA) révèle que toutes les différences observées entre les trois groupes distingués ici (graines, interviewé-e-s et non-interviewé-e-s) sont significatives au seuil de 1 %, respectivement pour chaque indice.

56 Dans tous les cas, les graines se distinguent par des indices de centralité moyens ou médians largement supérieurs au reste de l'échantillon – ce qui constitue un argument pour ne pas les prendre en compte dans les calculs des estimations, comme le préconisent certains auteurs (Volz & Heckathorn, 2008). On notera également que, pour les graines, l'étendue de la distribution est dans les trois cas relativement importante, illustrant ici aussi la variété des profils que nous avons initialement sélectionnés comme indicateurs et indicatrices privilégié-e-s.

57 Concernant la comparaison entre interviewé-e-s et non-interviewé-e-s, les différences entre indices de centralités restent la plupart du temps élevées. On peut néanmoins relever des écarts plus ou moins forts suivant le type d'indicateur. Si les personnes non-interviewées ont un indice moyen et médian d'intermédiarité proche de zéro, l'indice de centralité de vecteur propre leur est un peu moins défavorable. Ainsi, si les non-interviewé-e-s sont moins des ponts entre différents nœuds que les interviewé-e-s, il apparaît ici que les personnes interviewées ne sont pas nécessairement toutes et tous proches d'un des centres névralgiques du réseau analysé. Cette dernière remarque renvoie à la capacité du RDS de permettre de recruter certaines catégories de la population cible relativement moins accessibles directement.

58 Une approche diachronique permet d'affiner un peu plus ce constat. La Figure 5 représente la dispersion des différents indices de centralité des personnes interviewées en fonction de leur vague de recrutement. Sont également représentés les indices de centralité moyens des graines et des non-interviewé-e-s¹¹.

Figure 5. Dispersion des indices de centralités des interviewé-e-s en fonction de leur vague de recrutement

Lecture : Pour les personnes interviewées recrutées en vague 2, la valeur médiane de l'indice d'intermédiarité normalisé est de 6,4. Ici aussi, les points représentent les valeurs extrêmes à chaque vague.

59 Cette dernière analyse montre que la centralité plus importante des interviewé-e-s au regard des différents indicateurs est particulièrement forte dans les premières vagues

de recrutement. En revanche, plus on avance dans les vagues, plus les médianes des indices de centralité diminuent, se rapprochant de celles observées chez les personnes non-interviewées – et ce pour tous les indicateurs utilisés ici. Il en va de même concernant la dispersion : relativement importante en vague 1, elle se réduit significativement à partir de la vague 2. Cette dernière observation semble indiquer que si, dans un premier temps, certains individus particulièrement centraux sont recrutés en priorité, le profil des interviewé-e-s se lisse durablement une fois passé le cap de la deuxième vague.

- 60 La morphologie particulière que dessine l'évolution de la dispersion des indices de centralité au fil des vagues reflète d'une certaine manière les avantages d'un échantillonnage RDS par rapport à un recrutement moins standardisé. Les premières personnes rencontrées tendent à diriger les enquêteurs et enquêtrices vers certains individus qui sont bien souvent des nœuds importants au sein du réseau d'inter-collaboration. Pour s'éloigner durablement de ces centres névralgiques et espérer donner à voir d'autres dimensions du groupe social analysé, il est nécessaire de favoriser la multiplication des vagues de recrutement.

Conclusion

- 61 Pour conclure, il nous faut donc souligner que le RDS ne permet pas de transformer « miraculeusement » un échantillon sélectionné arbitrairement en échantillon probabiliste respectant les canons de la statistique inférentielle (Gile *et al.*, 2015). Certaines limites de cette méthodologie se font clairement jour dans nos analyses. Tout d'abord, il apparaît que les outils statistiques de redressement conçus en lien avec la procédure de recrutement s'avèrent d'autant plus performant que la population visée est moins « difficile à atteindre » que « rare ». Par ailleurs, à l'aune de la structuration du réseau de collaboration, les personnes interviewées se situent plus souvent proches des centres névralgiques de l'espace professionnel que celles et ceux n'ayant pas été recruté-e-s pour participer à l'enquête. Cette centralité plus manifeste des interviewé-e-s diminue cependant significativement au fur et à mesure que les vagues de recrutement s'éloignent des graines.
- 62 Néanmoins, dans les cas où une procédure d'échantillonnage traditionnel est impossible à mettre en place, les analyses menées ici nous portent à penser que cette méthode de recrutement et les outils statistiques qui y sont adossés permettent de récolter des données donnant un aperçu relativement fidèle de la population visée. Il faut par ailleurs préciser que si la procédure RDS peut paraître *a priori* relativement contraignante, elle donne de meilleurs résultats qu'une enquête web, procédé souvent utilisé aujourd'hui par les personnes désireuses de s'intéresser aux populations échappant traditionnellement au regard statistique institutionnel.
- 63 Nos résultats nous portent par ailleurs à penser que la réussite d'un tel dispositif dépend d'une quantité de paramètres – Quels sont les contours de la population cible ? Quelle est la nature exacte du lien sur lequel se base la diffusion de l'enquête ? Quel périmètre de validité souhaite-t-on viser potentiellement pour les résultats escomptés (une ville, une région, un pays, etc.) ? – relevant du travail de construction de l'objet de l'enquête et nécessitant une réflexion sociologique et épistémologique préalable approfondie. Aussi, au vu des potentialités de cette méthode, le débat autour du RDS et plus généralement de l'échantillonnage par réseau, principalement animé par des statisticien-ne-s jusqu'à aujourd'hui, mériterait d'être investi plus systématiquement par les sociologues.
- 64 Cette perspective de recherche nous semble une alternative prometteuse à certains problèmes auxquelles se heurtent aujourd'hui nombre d'enquêtes quantitatives en sciences sociales. Il apparaît en effet que les recherches actuelles incluant un volet quantitatif sont travaillées par deux tendances. D'une part, la multiplication des données numériques permet aujourd'hui d'envisager de travailler quantitativement et en finesse sur des objets qu'on ne pouvait jusqu'ici appréhender que grossièrement, quitte à parfois verser dans un « hyper-empirisme » (Ollion & Boelaert, 2015, p. 308). L'utilisation de tels corpus, certes souvent volumineux, mais dont la logique de constitution échappe en partie aux chercheurs et chercheuses en sciences sociales, ne permet généralement pas d'introduire de critères proprement sociologiques dans la définition du périmètre des populations d'enquête ou des variables à observer – à tel point qu'au sujet de nombreuses bases de données relevant du *big data*, il serait tentant de parler davantage de *poor data* (Ollion & Boelaert, 2015). D'autre part, la standardisation de nombreuses enquêtes institutionnelles peine à prendre en compte certaines mutations de la structuration des sociétés contemporaines – de sorte qu'il faut bien souvent bricoler pour impulser de nouvelles perspectives analytiques et ainsi

courir le risque de voir ses conclusions fortement critiquées par les tenants des méthodes inférentielles classiques, comme le montre la récente controverse autour de la « *Great British Class Survey* » (Mills, 2014 ; Savage *et al.*, 2013). Entre ces deux options (utiliser des données numériques abondantes mais de qualité incertaine ou se cantonner aux données tirées de grandes enquêtes, robustes mais trop standardisées), il nous semble que le développement de méthodes d'échantillonnage semblables à celle présentée ici dessine une troisième voie – permettant aux sociologues d'explorer quantitativement des terrains jusqu'ici en friche tout en bénéficiant d'outils théoriques et statistiques laissant envisager une possible généralisation.

Bibliographie

- Accominotti F.** (2009), « Creativity from Interaction : Artistic Movements and the Creativity Careers of Modern Painters », *Poetics*, vol. 37, no 3, pp. 267-294.
- Becker H. S.** (1985), *Outsiders : études de sociologie de la déviance*, Paris, Le Métailié.
- Bethlehem J.** (2010), « Selection Bias in Web Surveys », *International Statistical Review*, vol. 78, no 2, pp. 161-188.
- Buscatto M.** (2007), *Femmes du jazz : musicalités, féminités, marginalités*, Paris, Éditions du Cnrs.
- Coulangeon P.** (2004), *Les Musiciens interprètes en France. Portrait d'une profession*, Paris, La Documentation française.
- Dubois S. & François P.** (2013), « Career Paths and Hierarchies in the Pure Pole of the Literary Field : The Case of Contemporary Poetry », *Poetics*, vol. 41, no 5, pp. 501-523.
- Forsé M.** (2012), « Les réseaux sociaux d'aujourd'hui », *Revue de l'OFCE*, no 7, pp. 155-169.
- Gile K. J.** (2011), « Improved Inference for Respondent Driven Sampling Data with application to HIV Prevalence Estimation », *Journal of the American Statistical Association*, vol. 106, no 493, pp. 135-146.
- Gile K. J. & Handcock M. S.** (2010), « Respondent Driven Sampling : An Assessment of Current Methodology », *Sociological Methodology*, vol. 40, no 1, pp. 285-327.
- Gile K. J. & Handcock M. S.** (2015), « Network Model-assisted Inference from Respondent Driven Sampling Data », *Journal of the Royal Statistical Society : Series A (Statistics in Society)*, vol. 178, no 3, pp. 619-639.
- Gile K. J., Johnston L. G. & Salganik M. J.** (2015), « Diagnostics for Respondent Driven Sampling », *Journal of the Royal Statistical Society : Series A (Statistics in Society)*, vol. 178, no 1, pp. 241-269.
- Giuffrè K.** (1999), « Sandpiles of Opportunity : Success in the Art World », *Social Forces*, vol. 77, no 3, pp. 815-832.
- Goodman L. A.** (1961), « Snowball Sampling », *The Annals of Mathematical Statistics*, vol. 32, no 1, pp. 148-170.
- Grazian D.** (2004), « Opportunities for Ethnography in the Sociology of Music », *Poetics*, vol. 32, no 3, pp. 197-210.
- Gros J.** (2017) « Quantifier en ethnographe. Sur les enjeux d'une émancipation de la représentativité statistique », *Genèses*, no 108, pp. 129-147.
- Heckathorn D. D.** (1997), « Respondent Driven Sampling : A New Approach to the Study of Hidden Populations », *Social Problems*, vol. 44, no 2, pp. 174-199.
- Heckathorn D. D. & Jeffri J.** (2001), « Finding the Beat : Using Respondent Driven Sampling to Study Jazz Musicians », *Poetics*, vol. 28, no 4, pp. 307-329.
- Handcock M. S. & Gile K. J.** (2011), « Comment : On the Concept of Snowball Sampling », *Sociological Methodology*, vol. 41, no 1, pp. 367-371.
- Johnston L. G., McLaughlin K. R., El Rhilani H., Latifi A., Toufik A., Bennani A., Kalami A. & Handcock M. S.** (2015), « Estimating the Size of Hidden Populations Using Respondent Driven Sampling Data : Case Examples from Morocco », *Epidemiology*, vol. 26, no 6, pp. 846-852.
- Lahire B.** (2006), *La Condition littéraire : la double vie des écrivains*, Paris, La Découverte.
- Léon L., Jarlais D. D., Jauffret-Roustide M. & Strat Y. L.** (2016), « Update on Respondent Driven Sampling : Theory and Practical Considerations for Studies of Persons who Inject Drugs », *Methodological Innovations*, vol. 9, pp. 1-9.
- Lu X., Bengtsson L., Britton T., Camitz M., Kim B. J., Thorson A. & Liljeros F.** (2012), « The Sensitivity of Respondent Driven Sampling », *Journal of the Royal Statistical Society : Series A (Statistics in Society)*, vol. 175, no 1, pp. 191-216.
- Mc Pherson M.** (2001), « Sampling Strategies for the Arts : A Hypernetwork Approach », *Poetics*, vol. 28, no 4, pp. 291-306.
- McCreesh N., Copas A., Seeley J., Johnston L. G., Sonnenberg P., Hayes R. J., Frost S. D. W. & White R. G.** (2013), « Respondent Driven Sampling : Determinants of Recruitment and a Method to Improve Point Estimation », *PLOS ONE*, vol. 8, no 10, <http://journals.plos.org/plosone/article?id=10.1371/journal.pone.0078402>. DOI : 10.1371/journal.pone.0078402
- McCreesh N., Frost S., Seeley J., Katongole J., Tarsh M. N., Ndungu R., Jichi F., Lunel N. L., Maher D., Johnston L. G., Sonnenberg P., Copas A. J., Hayes R. J. & White R. G.** (2012), « Evaluation of Respondent Driven Sampling », *Epidemiology*, vol. 23, no 1, pp. 138-147.

- Menger P.-M.** (2010), « Les artistes en quantités. Ce que sociologues et économistes s'apprennent sur le travail et les professions artistiques », *Revue d'économie politique*, vol. 120, no 1, pp. 205-236.
- Milgram S.** (1967), « The Small World Problem », *Psychology Today*, vol. 1, pp. 61-67.
- Mills C.** (2014), « The Great British Class Fiasco : A Comment on Savage *et al.* », *Sociology*, vol. 48, no 3, pp. 437-444.
- Moeschler O.** (2011), *Cinéma suisse : une politique culturelle en action. L'État, les professionnels, les publics*, Lausanne, Presses polytechniques romandes.
- Mouw T. & Verdery A.M.** (2012), « Network Sampling with Memory : A Proposal for More Efficient Sampling from Social Networks », *Sociological Methodology*, vol. 42, no 1, pp. 206-256.
- OFS** (2010), *Les dépenses publiques en faveur de la culture en Suisse, 1990-2007*, Neuchâtel, Office fédéral de la Statistique.
- Ollion É. & Boelaert J.** (2015), « Au delà des big data. Les sciences sociales et la multiplication des données numériques », *Sociologie*, vol. 6, no 3, pp. 295-310.
- Perrenoud M.** (2006), « Jouer "le jazz" : où, comment ? Approche ethnographique et distinction des dispositifs de jeu », *Sociologie de l'Art*, no 1, pp. 25-42.
- Perrenoud M.** (2007), *Les musicos : enquête sur des musiciens ordinaires*, Paris, La Découverte.
- Perrenoud M.** (2013), « Résultats de l'enquête par questionnaire à l'initiative du SMS sur le soutien public local à l'activité musicale en Suisse », *Rapport au Syndicat musical suisse*, Zürich, Syndicat musical suisse.
- Perrenoud M. & Bataille P.** (2017), « Être musicien.ne interprète en Suisse romande. Modalités du rapport au travail et à l'emploi », *Revue suisse de sociologie*, vol. 43, no 2, pp. 309-334.
- Perrenoud M. & Chapuis J.** (2016), « Des arrangement féminins ambivalents : musiques actuelles en Suisse romande », *Ethnologie française*, vol. 46, no 1, pp. 71-82.
- Perrenoud M. & Leresche F.** (2016), « Les paradoxes du travail musical. Travail visible et invisible chez les musiciens ordinaires en Suisse et en France », *Les Mondes du travail*, no 15, pp. 87-98.
- Picaud M.** (2015), « Les salles de musique à Paris : hiérarchies de légitimité et manières d'entendre les genres musicaux », *Actes de la recherche en sciences sociales*, no 206-207, pp. 68-89.
- Ragin C. & Becker H.S.** (dir.) (1992), *What is a Case ? Exploring the Foundations of Social Inquiry*, Cambridge, Cambridge University Press.
- Salganik M.J.** (2012), « Commentary : Respondent Driven Sampling in the Real World », *Epidemiology*, vol. 23, no 1, pp. 148-150.
- Salganik M.J. & Heckathorn D.D.** (2004), « Sampling and Estimation in Hidden Populations Using Respondent Driven Sampling », *Sociological Methodology*, vol. 34, no 1, pp. 193-240.
- Savage M., Devine F., Cunningham N., Taylor M., Li Y., Hjelbrekke J., Le Roux B., Friedman S. & Miles A.** (2013), « A New Model of Social Class ? Findings from the BBC's Great British Class Survey Experiment », *Sociology*, vol. 47, no 2, pp. 219-250.
- Schiltz M.-A.** (2005), « Faire et défaire des groupes. L'information chiffrée sur les "populations difficiles à atteindre" », *Bulletin de méthodologie sociologique*, no 86, pp. 30-54.
- Spreen M.** (1992), « Rare Populations, Hidden Populations, and Link-tracing Designs : What and Why ? », *Bulletin de méthodologie sociologique*, no 36, pp. 34-58.
- Thompson S.K. & Collins L.M.** (2002), « Adaptive Sampling in Research on Risk-related Behaviors », *Drug and Alcohol Dependence*, no 68, pp. 57-67.
- Tyldum G., Rodrigues L., Bjørkhaug I. & Wojtynska A.** (2014), « Deciding on and Distributing Incentives in RDS », in Tyldum G. & Johnston L. (dir.), *Applying Respondent Driven Sampling to Migrant Populations : Lessons from the Field*, Palgrave Macmillan, Londres, pp. 49-61.
- Van Meter K.M.** (1990), « Methodological and Design Issues : Techniques for Assessing the Representatives of Snowball Samples », *NIDA Research Monograph*, vol. 98, pp. 31-43.
- Vessillier M.** (1989), « La démographie des créateurs », *Population*, vol. 44, no 2, pp. 291-310.
- Volz E. & Heckathorn D.D.** (2008), « Probability Based Estimation Theory for Respondent Driven Sampling », *Journal of Official Statistics*, vol. 24, no 1, pp. 79-97.
- Wejnert C.** (2009), « An Empirical Test of Respondent Driven Sampling : Point Estimates, Variance, Degree Measures, and Out-of-Equilibrium Data », *Sociological Methodology*, vol. 39, no 1, pp. 73-116.
- Wejnert C., Pham H., Krishna N., Le B. & DiNenno E.** (2012), « Estimating Design Effect and Calculating Sample Size for Respondent Driven Sampling Studies of Injection Drug Users in the United States », *AIDS and Behavior*, vol. 16, no 4, pp. 797-806.
- White R.G., Hakim A.J., Salganik M.J., Spiller M.W., Johnston L.G., Kerr L., Kendall C., Drake A., Wilson D., Orroth K., Egger M. & Hladik W.** (2015), « Strengthening the Reporting of Observational Studies in Epidemiology for Respondent Driven Sampling Studies : "STROBE-RDS" Statement », *Journal of Clinical Epidemiology*, vol. 68, no 12, pp. 1463-1471.

Notes

1 Une réponse possible aux problèmes que pose la sélection d'un échantillon « représentatif » est de se soustraire explicitement aux principes inférentiels pour se concentrer sur des « cas » situés dans l'espace social et d'interpréter les résultats obtenus à la lumière de ce travail de

contextualisation, comme le préconisent Charles Ragin et Howard Becker (1992) ou encore Julien Gros (2017).

2 Il faut rappeler que le *snowball sampling* tel que décrit par Leo Goodman en 1961 – qui propose d'inférer à partir de la structure des liens qu'entretiennent les individus issus d'un échantillon choisi aléatoirement – suit en fait

une procédure beaucoup plus stricte et spécifique que la majeure partie des recherches qui revendiquent pratiquer un échantillonnage « par boule de neige ». Aussi, parler d'échantillonnage « par dépistage de lien » (*link tracing*) apparaît une dénomination plus juste pour nommer les modes d'échantillonnages par interrelation dans toute leur diversité (Handcock & Gile, 2011).

3 Cette enquête, intitulée *Musician's LIVES*, a été menée dans le cadre du Pôle national de recherche (PNR) LIVES, soutenu par le Fond national suisse pour la recherche scientifique (FNS) – et plus précisément au sein du projet « Genre et Professions » dirigé par Nicky Le Feuvre.

4 La synthèse de la plupart des travaux parus au cours des années 2000 sur cette question porte à penser que la distance moyenne inter-individuelle à l'époque des réseaux sociaux et des connexions numériques se situe entre 4 et 7 degrés de séparation à l'échelle de la population mondiale – avec, bien entendu, d'importantes variations en fonction du contexte (Forsé, 2012, p. 164).

5 Pour un commentaire et une présentation plus complète, nous renvoyons à l'annexe électronique de cet article <https://journals.openedition.org/sociologie/3342>

6 Depuis la parution des premiers travaux de K. Gile, d'autres estimateurs (Gile & Handcock, 2015) et d'autres techniques d'échantillonnage inspirées du RDS, et censées en dépasser les limites, ont été formalisées, comme le

Network Sampling with Memories (Mouw & Verdery, 2012) par exemple. Par souci de concision, nous ne discuterons pas ici les perspectives ouvertes par ces travaux.

7 Dans les cas où la récolte d'informations sur les noms et prénoms pose problème, on peut signaler que, dans leur présentation de la méthode du *Network Sampling with Memories*, T. Mouw et A. Verdery détaillent différentes méthodes pour récolter des réseaux complets tout en préservant l'anonymat des personnes citées (Mouw & Verdery, 2012, p. 245).

8 Hormis les trois auteur-e-s de cet article, ont donc participé à la réflexion précédant la mise en place de l'enquête par questionnaire et aux opérations

de recueil des données Jérôme Chapuis, Sara Cordero, Frédérique Leresche et Noémie Merçay. Nous les remercions toutes et tous pour le travail en commun.

9 Les figures présentées dans cet article et son annexe électronique ont été réalisées grâce aux librairies GGally et ggplot2 du logiciel R.

10 En 2016, le salaire médian net en Suisse était de 4 040 euros par mois (source : Eurostat).

11 Pour la construction de cette figure, nous avons additionné les individus de la huitième et de la septième vague avec ceux de la sixième, car leurs effectifs étaient trop réduits.

Documents annexes

- Texte intégral disponible ici en accès libre ! (Lien externe)
- Annexe électronique de l'article « Échantillonner des populations rares. Une expérimentation du *Respondent Driven Sampling* en milieu musical » (Annexes électroniques)

Table des illustrations

Titre	Figure 1. Diffusion de l'enquête web
	URL	http://journals.openedition.org/sociologie/docannexe/image/3336/img-1.jpg
	Fichier	image/jpeg, 180k
Titre	Figure 2. Diffusion de l'enquête RDS
	Légende	Lecture : Les différents arbres de recrutement figurés ici représentent la diffusion de notre questionnaire web (Figure 1) et de notre enquête RDS (Figure 2). Les points de départ de chaque arbre sont les graines. Les noeuds du graphe représentent tous une personne ayant été contactée dans le cadre de l'une ou l'autre des enquêtes. Chaque embranchement de ces arbres est le début d'une nouvelle vague de recrutement.
	URL	http://journals.openedition.org/sociologie/docannexe/image/3336/img-2.jpg
Fichier	image/jpeg, 144k
	Titre	Figure 3. Le réseau des collaborations (2013)
	Légende	Lecture : Dans ce graphe, chaque lien représente une collaboration musicale entre deux personnes. La taille des noeuds est proportionnelle à leur nombre de sommets. Outre les personnes interviewées dans le cadre de notre enquête, ne sont figurés ici que les individus apparaissant au moins deux fois dans la liste des collaborations recueillies.
	URL	http://journals.openedition.org/sociologie/docannexe/image/3336/img-3.jpg
	Fichier	image/jpeg, 540k

Titre	Figure 4. Dispersion des indices de centralité des noeuds en fonction de leur statut Lecture : Pour les personnes interviewées, la médiane de la valeur normalisée de l'indice d'intermédiarité est de 6,5. Les points représentent les valeurs trop extrêmes pour être représentative de la distribution.NB : L'analyse de variance (ANOVA) révèle que toutes les différences observées entre les trois groupes distingués ici (graines, interviewé-e-s et non-interviewé-e-s) sont significatives au seuil de 1 %, respectivement pour chaque indice.
	URL	http://journals.openedition.org/sociologie/docannexe/image/3336/img-4.jpg
	Fichier	image/jpeg, 60k
Titre	Figure 5. Dispersion des indices de centralités des interviewé-e-s en fonction de leur vague de recrutement Lecture : Pour les personnes interviewées recrutées en vague 2, la valeur médiane de l'indice d'intermédiarité normalisé est de 6,4. Ici aussi, les points représentent les valeurs extrêmes à chaque vague.
	URL	http://journals.openedition.org/sociologie/docannexe/image/3336/img-5.jpg
	Fichier	image/jpeg, 90k

Pour citer cet article

Référence électronique

Pierre Bataille, Marc Perrenoud et Karen Brändle, « Échantillonner des populations rares », *Sociologie* [En ligne], N° 2, vol. 9 | 2018, mis en ligne le 01 octobre 2018, consulté le 08 octobre 2018. URL : <http://journals.openedition.org/sociologie/3336>

Auteurs

Pierre Bataille

Pierre.bataille@ulb.ac.be

Post-doctorant FNS, sociologue, ULB - Centre METICES, Université Libre de Bruxelles, Institut de Sociologie, 44 avenue Jeanne, 1050 Bruxelles, Belgique

Marc Perrenoud

Marc.Perrenoud@unil.ch

Maître d'enseignement et de recherche, sociologue, UNIL - LACCUS, UNIL, Quartier UNIL-Mouline, Bâtiment Géopolis, 1015 Lausanne, Suisse

Karen Brändle

karen.brandle@unil.ch

Doctorante, psychologue sociale, UNIL - LINES, UNIL, Quartier UNIL-Mouline, Bâtiment Géopolis, 1015 Lausanne, Suisse

Droits d'auteur

© tous droits réservés