

eman ta zabal zazu



Universidad
del País Vasco

Euskal Herriko
Unibertsitatea

Tesis Doctoral

DESARROLLO DE UN SISTEMA DE IDENTIFICACION DE PACIENTES DE ALTO RIESGO EN EL PAIS VASCO

Autor

Juan Francisco Orueta Mendia

Directores

Dr. Juan José Aurrekoetxea Agirre

Dr. Manuel García Goñi

Departamento de Medicina Preventiva y Salud Pública

Programa de Doctorado de Salud Pública

2016

AGRADECIMIENTOS.

Durante bastantes años he compaginado mi labor como clínico en la consulta con la participación en proyectos de investigación. Por tanto, el documento que aquí presento ha sido realizado durante un periodo prolongado de tiempo y su elaboración hubiera sido imposible sin la ayuda de muchas personas. Sus enseñanzas, apoyo y las críticas constructivas me han permitido llevar a cabo este trabajo. Aunque citarlos a todos resulta inviable, no puedo menos que destacar a algunos de ellos.

Cronológicamente, Gontzal Grandes fue la persona que me contagió el interés por la investigación. Fueron él y Josefina López de Muniain los que guiaron en mis primeros proyectos.

Andoni Foruria y Fernando Urbano, desde la Subdirección de Atención Primaria, se convencieron de la utilidad práctica de mi trabajo y me ayudaron a aplicarlo.

Santi Esnaola me hizo comprender la importancia de los factores socioeconómicos para explicar la salud de las poblaciones.

Roberto Nuño, en su etapa de Director de oBerri, fue uno de los líderes destacados en la implantación de la Estrategia para afrontar el reto de la Cronicidad en Euskadi y quien me permitió estar al frente del Programa de Estratificación Poblacional. Gran parte de mi trabajo posterior es resultado de aquella experiencia.

Maidier Mateos y Edurne Alonso con quienes colaboré en dicho programa.

Arturo Garcia demostró auténtica paciencia al tratar de hacerme entender los complejos modelos matemáticos que maneja. Su innegable interés por la estadística, su curiosidad por comprobar la validez de los modelos predictivos y el esfuerzo desinteresado que ha dedicado han resultado elementos fundamentales. Sin ellos me hubiera sido imposible completar este trabajo.

Por último, mis directores de tesis. Juanjo Aurrekoetxea fue quien me propuso realizarla, me ha ido guiando en las diferentes etapas y me ha ayudado a darle forma. Los acertados comentarios y críticas de Manuel García Goñi han permitido mejorar la calidad del resultado.

1. INTRODUCCION	1
1.1 Necesidad de adaptación de los sistemas de salud al nuevo patrón epidemiológico de la población	1
1.1.1 La multimorbilidad, un fenómeno frecuente.....	1
1.1.2 Causas de la multimorbilidad.....	4
1.1.3 Relación entre multimorbilidad y privación socioeconómica.....	5
1.1.4 Consecuencias de la multimorbilidad para los pacientes	7
1.1.5 Consecuencias de la multimorbilidad para la provisión de cuidados sanitarios. Calidad de la atención	9
1.1.6 Resultados de la atención sanitaria a pacientes pluripatológicos	12
1.1.7 Consecuencias de la multimorbilidad para los sistemas de salud	15
1.1.8 Nuevos modelos de provisión de cuidados sanitarios	18
1.2 Sistemas de evaluación y ajuste de riesgos.....	20
1.2.1 Evaluación y ajuste de riesgo	20
1.2.2. Limitaciones de los modelos estadísticos para evaluación de riesgos.....	23
1.2.3 Empleo de los modelos de ajuste de riesgo en nuestro medio	23
1.3 Implantación del programa de estratificación poblacional en el país vasco. Resultados en el primer año	25
1.3.1 Seleccionando pacientes para realizar intervenciones en el País Vasco	25
1.3.2 Procedimientos de clasificación.....	26
1.3.2.1 Fuentes de información.	26
1.3.2.2 Datos incluidos	27
1.3.2.3 <i>Case-mix</i>	28
1.3.2.4 Clasificación de diagnósticos.....	28

1.3.2.5	Identificación de problemas de salud a partir de las prescripciones.....	29
1.3.2.6	Desarrollo del modelo predictivo.....	31
1.3.3	Resultados y aplicaciones de la clasificación de pacientes.....	36
1.3.3.1	Agrupación de diagnósticos y medicaciones.....	36
1.3.3.2	Estratificación de los pacientes y aplicaciones en el País Vasco.....	38
A)	Nuevos roles de enfermería: Enfermera Gestora de Competencias Avanzadas.	38
B)	Batera-Zainduz: Compartiendo cuidados en la atención al paciente con diabetes mellitus.....	41
C)	Aplicación en la evaluación de la Oferta Preferente.....	44
1.3.4.	Lecciones aprendidas a partir de la aplicación de la estratificación poblacional en el País Vasco.....	46
1.4	Difusión de la estratificación en el mundo real: el punto de vista de los clínicos.	47
1.5	Índices de comorbilidad.....	50
1.6	Diseño de un nuevo sistema de estratificación poblacional en el país vasco.....	52
2.	HIPOTESIS y OBJETIVOS:.....	53
2.1	Hipotesis.....	53
2.2	Objetivos.....	55
3.	DESARROLLO DE LOS OBJETIVOS DEL ESTUDIO.....	57
3.1	OBJETIVO 1: Describir la prevalencia y costes de la multimorbilidad en el País Vasco.....	57
3.2	OBJETIVO 2: Determinar la validez de los sistemas de ajuste de riesgo poblacional en nuestro medio.....	70
3.3	OBJETIVO 3: Explorar el proceso de implantación de la estratificación poblacional en el País Vasco desde el punto de vista de los clínicos e identificar elementos relevantes, que pudieran actuar como facilitadores o barreras.....	81

3.4 OBJETIVO 4: Establecer la validez de un nuevo sistema de clasificación de pacientes y su aplicabilidad como instrumento de estratificación poblacional.	93
3.4.1 Introducción	93
3.4.2 Métodos	95
3.4.2.1 Evaluación Ética.....	95
3.4.2.2 Descripción población de estudio	95
3.4.2.3 Fuentes de información	98
3.4.2.4 Fases en la clasificación de los pacientes y elaboración del algoritmo agrupador de enfermedades crónicas.	99
3.4.2.4.1 Identificación de las Patologías Crónicas.	99
3.4.2.4.2 Creación de los Grupos de Enfermedades Crónicas (GRECs):.....	102
3.4.2.4.3.- Adjudicación de puntuaciones a los GRECs:	114
3.4.2.4.4.- Inclusión de las variables demográficas y de utilización previa de recursos.	116
3.4.2.5 Variables de estudio y modelos estadísticos para validación del sistema FINGER.....	118
3.4.2.6 Comparación de la capacidad predictiva de FINGER con otros métodos. ...	119
3.4.3 Resultados	123
3.4.3.1 Distribución de pacientes.....	123
3.4.3.2 Validación del sistema FINGER en la población general, frente a los resultados obtenidos por otros sistemas.....	127
3.4.3.3 Comprobación de la validación del sistema en los grupos analizados de manera individualizada, por su especial interés.	132
3.4.4 Discusión del Objetivo 4.....	141
3.4.4.1 Resultados principales y comparación con otros sistemas de estratificación	141
3.4.4.2 Posibles aplicaciones de FINGER en los sistemas de salud	146

3.4.4.3 Limitaciones	147
4. DISCUSION.....	149
4.1 Importancia de la multimorbilidad en el País Vasco	149
4.2 Validación en nuestro medio de sistemas de ajuste poblacional diseñados en otros países.....	152
4.3 Percepciones de los clínicos acerca de la estratificación poblacional	155
4.4 FINGER. Un nuevo sistema de estratificación poblacional.....	157
Característica del sistema FINGER.....	158
5. SINTESIS.....	160
6. CONCLUSIONES.	164
REFERENCIAS.....	167

1. INTRODUCCION

1.1 NECESIDAD DE ADAPTACIÓN DE LOS SISTEMAS DE SALUD AL NUEVO PATRÓN

EPIDEMIOLOGICO DE LA POBLACIÓN

1.1.1 La multimorbilidad, un fenómeno frecuente.

A lo largo de las últimas décadas, las organizaciones sanitarias han comprobado un cambio progresivo en la tipología de pacientes a los que atienden. La presencia de múltiples patologías en una misma persona es un hallazgo cada vez más habitual, hasta el punto de que actualmente se considera que la enfermedad crónica más frecuente en nuestra población es la multimorbilidad (1).

Diversos factores contribuyen a explicar parcialmente este fenómeno. El primero el envejecimiento poblacional (2). Según estimaciones del Instituto Nacional de Estadística (INE), la esperanza de vida al nacer era en España en el año 2014 de 80,1 años para varones y 85,6 en mujeres(3). Actualmente, el porcentaje de mayores de 65 años es ya el 18% de la población española y, según proyecciones del propio INE, este porcentaje aumentará al 22% en 2024 y, de ellos, más de un 1.750.000 personas sobrepasarán la edad de 85 años (4).

Otros determinantes de este fenómeno guardan relación con estilos de vida no saludables, como son el sedentarismo y la ingesta calórica excesiva. Según datos de la OMS, en los países desarrollados, más de la mitad de los adultos tienen una actividad física insuficiente (5).

Una tercera causa potencial es resultado de la práctica sanitaria y la existencia de terapias más eficaces. Por otra parte, la modificación de criterios diagnósticos o la aceptación de nuevas patologías puede explicar en algunos casos, de manera parcial, el aumento de personas que han sido diagnosticadas de enfermedades crónicas (6).

Sin embargo, la multimorbilidad no es un hallazgo exclusivamente limitado a las poblaciones envejecidas. Hace ya más de 30 años, Starfield comprobó en poblaciones pediátricas que el número de personas que presentan problemas de salud múltiples, aparentemente no interrelacionados, es superior al que cabría esperar en base al azar (7).

En los últimos años se han publicado numerosos estudios para determinar la prevalencia de multimorbilidad en la población, empleando diferentes metodologías; como consecuencia, también resultan dispares los valores obtenidos. Tales diferencias metodológicas incluyen aspectos tan importantes como: el tipo y número de enfermedades crónicas observadas; el número de enfermedades concomitantes requeridas para que una persona fuera considerada pluripatológica; las fuentes de información; las características demográficas de las poblaciones analizadas; y el método de captación de las personas. Así, en una revisión sistemática Fortin y otros (8) observaron que la prevalencia de multimorbilidad en la población oscilaban entre 13 y 71%. En la revisión de Marengoni (9) sobre estudios de multimorbilidad en ancianos realizado sobre 41 publicaciones, mostraron cifras entre 55 y 98%. Más recientemente, para su revisión, Salive (10) identificó 4.858 referencias de las cuales seleccionó finalmente 17 publicaciones; la mediana de resultados obtenidos por los distintos autores incluidos fue 63%, con una moda de 67% y un rango comprendido entre 20 y 75%.

Sin embargo, publicaciones aparecidas en los últimos años que han analizado grandes poblaciones han obtenido cifras de prevalencia similares a pesar del empleo de fuentes de información muy distintas. Barnett y otros (11) trabajaron con una base de datos de la red de

atención primaria que incluyó una tercera parte de la población escocesa (n= 1.751.841); consideraron que el porcentaje de pacientes multimórbidos fue 23,2% para la población general y 67,0% en mayores de 65 años. Ward (12), a partir de la Encuesta Nacional de Salud de Estados Unidos (National Health Interview Survey [NHIS]) que analizó una muestra representativa de la población norteamericana mayor de 18 años (n = 27.157), concluyó que la multimorbilidad afectaba al 23,6% de todas las personas y al 62,5% de los mayores de 65 años.

En el País Vasco, con fines de investigación, se creó una base de datos que incluye a todos los habitantes que disponen de aseguramiento público en nuestra comunidad, esto es, más de dos millones de habitantes. Dicha base compila información procedente de atención primaria, atención especializada sin ingreso, servicios de urgencias e ingresos en hospital. Permite identificar los problemas de salud que sufren las personas a partir de los diagnósticos o fármacos que se les han prescrito. La explotación de la información allí contenida determinó que la multimorbilidad afectaba al 23,6% de toda la población de nuestra Comunidad Autónoma y al 66,1% de mayores de 65 años (13).

Así pues, parece razonable afirmar que, aproximadamente, una de cada cuatro personas se ve afectada por dos o más enfermedades crónicas y que esta proporción alcanza a dos de cada tres entre los mayores de 65 años. Este hecho supone un reto para las organizaciones sanitarias que, tradicionalmente, fueron diseñadas para proporcionar atención a problemas agudos de salud y, en consecuencia, se están viendo obligadas a reinventar el modelo de prestación de cuidados sanitarios (14).

1.1.2 Causas de la multimorbilidad.

A pesar de su elevada prevalencia, muchos aspectos de la multimorbilidad aún no son bien conocidos. Debe tenerse en cuenta que la coexistencia de dos o más diagnósticos de enfermedades crónicas en una misma persona puede deberse a múltiples motivos (9,15). En primer lugar, una persona puede presentar dos patologías crónicas simplemente como resultado del azar (multimorbilidad coincidente); esto es, la frecuencia esperada de encontrar una combinación de dos enfermedades no relacionadas en una población es igual producto de las prevalencias de ambas patologías por separado. Sin embargo, en muchas ocasiones la frecuencia observada de estas combinaciones de enfermedades supera al valor esperado, para lo cual pueden encontrarse diversas explicaciones. En algunos casos puede deberse a un sesgo de selección; las personas a las que se les ha diagnosticado una patología crónica deben volver a visitar de forma repetida los servicios de salud para el control de esta enfermedad y, de este modo, se multiplica la probabilidad de que se les adjudiquen diagnósticos adicionales. Si bien este hecho ha sido comprobado en algunos estudios (9), en otros casos se ha constatado que los pacientes ancianos y aquellas personas que presentan problemas complejos de salud, son precisamente los grupos en los que los cuales los médicos encuentran mayor dificultad para registrar y codificar adecuadamente sus enfermedades, lo que conduce a un infrarregistro de diagnósticos en estos grupos poblacionales (16). Por último, cuando una combinación de enfermedades es más frecuente de lo esperado en función del azar y se ha descartado la presencia de sesgos puede pensarse en la existencia de una verdadera asociación; muchos factores genéticos, ambientales o psicosociales pueden aumentar la susceptibilidad a más de una enfermedad, lo que favorecerá la presencia de tales patologías en la misma persona:

- Algunas enfermedades son consecuencia directa de otras (por ejemplo, la retinopatía puede ser provocada por diabetes mellitus), a lo que se denomina asociación causal.
- En otras ocasiones un grupo de patologías puede compartir factores de riesgo comunes: por ejemplo, el sedentarismo se asocia, entre otras, con diabetes, enfermedades cardiovasculares, osteoporosis y depresión.
- Por otro lado, los factores de riesgo de algunas patologías se encuentran interrelacionados: el consumo de alcohol y tabaco por una misma persona es una situación frecuente, lo que aumenta la probabilidad de sufrir cirrosis y otras enfermedades digestivas, enfermedades cardiovasculares, cánceres diversos y enfermedades pulmonares.

1.1.3 Relación entre multimorbilidad y privación socioeconómica

En las poblaciones más desfavorecidas desde el punto de vista socioeconómico son más frecuentes las enfermedades (17,18). Por ello, también es más alta la prevalencia de multimorbilidad, como ha sido confirmado en diversas publicaciones (11,19,20). En el País Vasco, se llevó a cabo un estudio que abarcaba a la totalidad de la población de la comunidad autónoma e incluía información de todos los contactos de las personas con el servicio vasco de salud (21). Para detectar las patologías de las personas se utilizó información procedente de fuentes complementarias: diagnósticos (de altas de hospital, visitas a urgencias y atención primaria) y prescripciones de los médicos de primaria. Además, como variable socioeconómica, se contó con el índice de privación socioeconómica del área de residencia de las personas. La prevalencia de multimorbilidad resultó notablemente más alta entre los

habitantes de las zonas más pobres, con respecto a los de las áreas menos desfavorecidas (26,1% vs. 20,5%).

Aunque la relación entre nivel socioeconómico bajo y peor salud es compleja y los mecanismos de tal asociación no han sido establecidos de manera inequívoca, sí podemos encontrar algunas explicaciones. Analizando las enfermedades crónicas de manera individualizada, las mayores desigualdades se observaron en patologías relacionadas con conductas de riesgo, abuso de sustancias (tabaco, alcohol y otras), sedentarismo y exposición a factores ambientales o relativos al ambiente laboral (21). Sin embargo, los dos sexos no muestran patrones análogos y, en general, se observan diferencias más notables entre mujeres que entre hombres. Un hecho conocido es que la magnitud de las desigualdades entre niveles socioeconómicos varían según el sexo para muchos factores de riesgo. Por ejemplo, en el tabaquismo (22) o abuso de alcohol (23) las discrepancias son más importantes en el sexo masculino, mientras para obesidad las diferencias son mayores entre mujeres. Este hecho ayuda a explicar, al menos parcialmente, las diferencias sociales en diabetes observadas en el sexo femenino (18,24–26).

Los resultados del estudio del País Vasco concuerdan con los publicados por otros autores que han empleado otras fuentes de información, como son registros de atención primaria (11,27,28), encuestas a la población general (19) o usuarios de determinados tipos de servicios sanitarios (29), o entrevistas a médicos y pacientes (20). La mayor parte de tales estudios han sido llevados a cabo en países desarrollados, pero también existen evidencias en otros de medianos y bajos ingresos (30,31).

1.1.4 Consecuencias de la multimorbilidad para los pacientes

A pesar de que desde un punto de vista intuitivo pueda parecer muy obvia la relación entre multimorbilidad y limitación funcional, peor calidad de vida, dependencia y mayor mortalidad, tales relaciones todavía son objeto de investigación y debate. Las complejas interrelaciones de múltiples problemas de salud afectan de diferentes modos al tratamiento, capacidad del paciente para hacer frente a la enfermedad y calidad de vida (32).

Aunque diversos investigadores han establecido una asociación entre pluripatologías e incapacidad funcional y menor calidad de vida, sus conclusiones no son unánimes (9,10). Un hecho a tener en cuenta es que, incluso ajustando por múltiples factores de confusión, los modelos estadísticos empleados para analizar la relación entre enfermedades crónicas y calidad de vida muestran una capacidad explicativa modesta (estimada a partir de los valores de sus coeficientes de determinación) (33,34).

Algunos autores describen una relación casi lineal entre el número de enfermedades crónicas y la reducción en calidad de vida (35). Sin embargo, otros encuentran un efecto techo, que se alcanza a partir de la segunda comorbilidad: un mayor número de enfermedades crónicas únicamente implica pequeños detrimentos en calidad de vida (33,36). Por su parte, Glalenkamp analizó datos de una muestra de adultos de edades entre 55 y 85 años en Holanda (37); sus análisis muestran una asociación no lineal entre multimorbilidad y autopercepción de salud: si bien existe una disminución en salud autopercebida a medida que aumenta el número de enfermedades, el efecto negativo de la primera enfermedad es superior al de las subsiguientes y, de hecho, a partir de la segunda la adición de nuevas patologías va produciendo impactos progresivamente menores. Solamente en las edades más avanzadas se observa un efecto acumulativo lineal.

El estudio de las diferentes combinaciones de enfermedades también ha sido objeto de trabajos de investigación. Algunos autores consideran que el efecto de un conjunto de enfermedades sobre la incapacidad, autopercepción de salud y calidad de vida es el equivalente a la suma del efecto de cada una de ellas, sin que exista un efecto sinérgico entre las mismas (38). Sin embargo, otros trabajos muestran resultados muy diferentes. Así, Mujica-Mota estudió la presencia de 13 problemas crónicos de salud una muestra representativa de pacientes atendidos en atención primaria en Inglaterra (English General Practice Patient Survey) (39); a partir del análisis de sus datos, concluye que la presencia de tres o más patologías se asocia, en casi todos los casos, con una reducción mayor en calidad de vida que la estimada a partir de las sumas de los valores encontrados en cada enfermedad por separado. Por último, en otras publicaciones se describen efectos no lineales (interacciones sinérgicas o sustractivas) dependiendo de las patologías concretas. Por ejemplo, la combinación de diabetes mellitus con insuficiencia coronaria (34) o con cataratas (40) supone un detrimento en calidad de vida superior al esperado, mientras que la concurrencia de asma y enfermedad pulmonar obstructiva crónica presenta un efecto en dirección opuesta (40).

Recientemente ha sido publicada una revisión sistemática (41) que explora la relación entre multimorbilidad y deterioro funcional, definido como un declive en las habilidades para el autocuidado, acompañado de una disminución de la autonomía funcional y aumento de la incapacidad. Dicha revisión incluye 37 artículos, muchos de los cuales corroboran dicha asociación. Es de destacar que 9 de ellos son estudios de cohortes y 7 de los 9 concluyen que la multimorbilidad predice un futuro deterioro funcional. Tal deterioro se vuelve más evidente a medida que aumenta el número de patologías y también se asocia con la severidad de las enfermedades.

Los resultados de la multimorbilidad sobre el incremento en mortalidad presentan aún mayores controversias. Las enfermedades crónicas pueden ser muy diferentes en términos de severidad y un mayor número de patologías no necesariamente tendrá un mayor impacto sobre la supervivencia. Como Marengoni propone, la severidad de las enfermedades, su duración y las interacciones entre enfermedades agudas y crónicas probablemente son más importantes que la suma de patologías crónicas respecto al riesgo de mortalidad. (9)

1.1.5 Consecuencias de la multimorbilidad para la provisión de cuidados sanitarios. Calidad de la atención

La asistencia a los enfermos crónicos y pacientes con necesidades complejas supone un desafío. Con frecuencia no se dispone de instrumentos adecuados para su tratamiento. Las guías de práctica clínica (GPC) se han diseñado para ayudar a tomar decisiones en el tratamiento de enfermedades específicas. Se basan en la evidencia y en el consenso de expertos y se ha comprobado que su empleo contribuye a disminuir variaciones innecesarias en la práctica clínica y contribuyen a que se reduzca la mortalidad y la tasa de hospitalizaciones. Sin embargo, resulta necesario reconocer que los autores de las GPC deben mantener un equilibrio entre la claridad y la relativa brevedad de sus recomendaciones, evitando extenderse de manera excesiva sobre las situaciones complejas del mundo real (42). Por ello, presentan estándares de cuidados habitualmente dirigidos a enfermedades individuales y puede resultar difícil ajustar sus recomendaciones a las personas que presentan múltiples patologías (43). Aplicando las GPC a estos pacientes se requeriría un plan terapéutico que incluyera una gran cantidad de intervenciones y, aunque algunas de ellas pueden estar recomendadas en más de una patología, con frecuencia se producirían contradicciones entre ellas. Así, resulta probable que una persona con tres o más enfermedades debiera ser tratada

simultáneamente con múltiples fármacos distintos, aumentando el riesgo de errores de prescripción o administración, efectos secundarios, interacciones entre los medicamentos o eventos adversos. Un régimen terapéutico de este tipo puede suponer una carga difícil de soportar para el paciente y su familia, lo que, además, influirá negativamente en la adherencia al mismo (44).

Las amenazas de la polifarmacia han sido comprobadas por Dumbreck y otros (42), que recientemente han publicado una revisión. Para ello, seleccionaron las GPC de 3 enfermedades índice: diabetes mellitus, insuficiencia cardiaca y depresión. De manera exhaustiva buscaron posibles interacciones entre sus recomendaciones con las GPC de otras 11 comorbilidades potenciales. Dichas interacciones fueron categorizadas en fármaco-enfermedad (si el fármaco recomendado para alguna de las 3 enfermedades índice debería ser evitado en presencia de alguna de las 11 comorbilidades) o fármaco-fármaco (cuando la acción o efecto de un fármaco se veía modificado por la administración simultánea o sucesiva de un segundo, recomendado en el tratamiento de las comorbilidades). Encontraron que las interacciones fármaco-enfermedad no resultan frecuentes (excepto en insuficiencia renal), pero sí lo son las fármaco-fármaco. Describen 133 interacciones farmacológicas importantes en diabetes, 89 en depresión y 111 en insuficiencia cardiaca; de ellas, aproximadamente un 20% se producen entre los medicamentos recomendados como de primera línea. Sólo un número muy limitado de las interacciones que Dumbreck describe estaban incluidas en las GPC (2 en diabetes, 1 en depresión y ninguna en insuficiencia cardiaca).

Habitualmente los médicos coinciden en la utilidad de las GPC y solo se apartan de sus recomendaciones al asistir a personas con multimorbilidad cuando pueden aportar buenas razones para hacerlo, en función de las necesidades individuales y preferencias de los pacientes (45). Un interés excesivo de los gestores, poniendo más presión sobre los clínicos en

la aplicación acrítica de GPC entraña el riesgo de que éstos abandonen este enfoque basado en la persona, lo cual supone una amenaza para los pacientes con necesidades complejas.

A pesar de las dificultades que encuentran los médicos para dedicar el tiempo requerido a cada persona con pluripatologías y, contrariamente a lo que cabría esperar, los indicadores de proceso de la calidad de la atención (IPCA) en estos pacientes son, muchas veces, no inferiores al de otras personas. Higashi estudió el efecto del número de enfermedades crónicas que presentaba una persona con tales IPCA; analizando tres cohortes de pacientes americanos comprobó que la puntuación IPCA aumentaba progresivamente en función del número de enfermedades (46). Este hallazgo fue corroborado, al menos parcialmente, en otras poblaciones (47). En otros casos, los resultados dependen del tipo patologías; cuando coexisten patologías concordantes (esto es, las que comparten el mismo perfil de riesgo fisiopatológico y resulta más sencillo que sean integradas en un mismo plan de terapéutico) se observan mejores resultados en los IPCA; sin embargo, cuando coinciden comorbilidades no concordantes o se combinan enfermedades físicas y mentales no se encuentra esta asociación (48) o, incluso, se obtienen resultados peores (49–51). Así, Turner (50) comprobó que en pacientes con hipertensión no controlada la probabilidad de que recibieran un fármaco adicional más, disminuía progresivamente en función del número de enfermedades crónicas concurrentes no-relacionadas; el trabajo de Ricci-Cabello (49), realizado en pacientes con diabetes mellitus, también concuerda con esta línea, si bien se observan algunas excepciones. Incluso, Min (52) identificó un grupo de patologías (como la incontinencia urinaria o demencia) a las que denominó geriátricas, en función de su etiología multifactorial e inicio en edades avanzadas. A diferencia de las otras comorbilidades, las geriátricas mostraron un fuerte efecto negativo sobre los IPCA.

Existen diversos factores que pueden ayudar a explicar estas diferencias. Aunque pudiera pensarse que los pacientes pluripatológicos deben acudir con frecuencia a los servicios de

salud, lo cual proporciona a los clínicos un mayor número de oportunidades para evaluar su situación, actualizar sus tratamientos y realizar las intervenciones diagnósticas o terapéuticas que necesiten, tal hipótesis debe descartarse pues los resultados de los estudios citados en párrafo anterior han sido ajustados por número de visitas al médico. Una explicación plausible puede hallarse en la propia naturaleza de las combinaciones de patologías: por ejemplo, un médico puede estar más interesado en el control de la presión arterial en un paciente diabético que en uno que no lo es, debido a la importancia de evitar de evitar un daño adicional y mayores complicaciones vasculares (47). Por otra parte, especialmente en el caso de comorbilidades no relacionadas, pueden generarse recomendaciones muy numerosas entre las cuales se diversifican los esfuerzos de los clínicos: en un paciente pluripatológico, cada enfermedad adicional requiere intervenciones añadidas a las anteriores y, por tanto, mayor probabilidad de recibir tratamiento subóptimo en alguna de ellas. Además, el médico y el paciente pueden discrepar respecto a qué problemas de salud o qué recomendaciones deben priorizarse (53). En tercer lugar, los indicadores que tradicionalmente se utilizan pueden ser apropiados para medir la calidad de la atención en enfermedades aisladas, pero pudieran no ser aplicables a los objetivos adecuados para los pacientes con multimorbilidad.

1.1.6 Resultados de la atención sanitaria a pacientes pluripatológicos

Las personas con patologías múltiples tienen un mayor riesgo de sufrir incidentes de seguridad en la atención sanitaria, lo cual puede atribuirse a diversos motivos. Su manejo terapéutico presenta una complejidad intrínseca. Además, la posible fragmentación de sus cuidados entre diferentes especialidades/niveles de atención y su comunicación con los clínicos a los que visitan puede ser difícil y deficiente. Particularmente, algunas peculiaridades de estos pacientes (como avanzada edad, mala salud, trastornos cognitivos o dificultades para la

lectura) pueden incrementar su vulnerabilidad a estos problemas. En un metaanálisis, Panagioti (51) estableció que la multimorbilidad duplica ($OR=1,95$) el riesgo de eventos de seguridad activos, es decir, situaciones en las que la atención sanitaria generó un daño al paciente (tanto relacionadas con medicación [$OR=2,10$] como de otro tipo [$OR=1,80$]), e incrementa en un 16% ($OR=1,16$) la probabilidad de precursores de incidentes (como errores detectados en los diagnósticos y en las prescripciones o falta de adherencia al tratamiento, aunque no llegó a comprobarse un daño directo al paciente). Aunque sus resultados no permiten establecer las causas de estas asociaciones, sugieren que estos fallos en la seguridad pueden ser susceptibles de intervención mediante modelos de atención para los pacientes pluripatológicos centrados en la persona, en vez de las patologías individuales.

Los pacientes complejos y con multimorbilidad, a diferencia de otras personas, perciben con frecuencia brechas en la continuidad de los cuidados y detectan deficiencias en la comunicación y coordinación entre los profesionales. La no resolución de tales brechas tiene consecuencias negativas para los pacientes, produciendo situaciones de malestar y angustia. Algunos refieren pérdida de confianza y alejamiento del sistema sanitario (54) y también muestran menor satisfacción en su relación con atención primaria. Shadmi estudio una muestra de pacientes americanos mayores de 65 años de edad (55), que dividió en dos grupos según su carga de morbilidad. Evaluó la percepción de la calidad de atención primaria por los pacientes de ambos grupos mediante un cuestionario, que exploraba seis componentes clave: comunicación médico-paciente, trato interpersonal, conocimiento de la situación del paciente por parte del médico, integración de la atención, confianza y accesibilidad. Los pacientes con múltiples patologías (mayor carga de morbilidad) refirieron calidad inadecuada y descontento con la asistencia, presentando puntuaciones más bajas en todos los componentes. También, en este sentido, una encuesta nacional de la población inglesa sobre sus experiencias en atención primaria determinó la existencia de un gradiente: a mayor número de comorbilidades

menor satisfacción general, tanto al evaluar la accesibilidad telefónica, facilidad para obtener una cita, comunicación con los profesionales (repcionista, enfermera o médico), como la valoración global del servicio (56). Sus resultados indican que las experiencias vividas por los pacientes complejos y sus necesidades de atención son diferentes a los que sólo presentan una enfermedad crónica o ninguna.

La multimorbilidad también se asocia con peores resultados de la atención. Un método comúnmente utilizado para la evaluación de tales resultados consiste en la cuantificación de las hospitalizaciones evitables (ACSC [*Ambulatory Care Sensitive Conditions*]) (57). Las ACSC constituyen un listado de motivos de hospitalización, cuya necesidad de ingreso hubiera podido ser evitada por la prestación de cuidados ambulatorios efectivos y oportunos, a través de las siguientes intervenciones: prevención primaria, diagnóstico y tratamiento precoz en enfermedades agudas, o adecuado control y seguimiento en las patologías crónicas. Aunque como fuente de información utilizan solamente datos procedentes de altas hospitalarias, nos proporcionan una estimación indirecta de la accesibilidad y capacidad resolutive de todos los niveles de atención. Algunos estudios han descrito de esta manera los cuidados a enfermos en situación de cronicidad y pluripatología. Saver encontró una fuerte relación entre enfermedades crónicas individuales y un riesgo más elevado de ingreso por ACSC incluso por causas agudas (por ejemplo, neumonía); su hipótesis de contraste fue que algunos factores pueden predisponer a esas poblaciones vulnerables a sufrir esos problemas agudos (por ejemplo, las personas con enfermedades pulmonares crónicas son más propensos a presentar neumonías) y que las situaciones subyacentes de fragilidad (por ejemplo, demencia) incrementan notablemente el riesgo de ingreso cuando la enfermedad aguda se desarrolla (58). Wolf comprobó que la probabilidad de ingreso en hospital por causas evitables aumentaba de manera exponencial en los enfermos pluripatológicos, hasta multiplicarse casi por cien en los que tenían 4 o más enfermedades (59). Payne estudió el efecto del número de

enfermedades crónicas sobre los ingresos no programados (tanto evitables como de otro tipo); en ambos tipos de ingresos no programados, las tasas de hospitalización se elevaban de manera progresiva a medida que se incrementaba el número de comorbilidades por persona (60). Los aumentos de hospitalizaciones observados en estos estudios indican que parece poco probable que los enfermos pluripatológicos estén recibiendo cuidados apropiados y de suficiente calidad.

1.1.7 Consecuencias de la multimorbilidad para los sistemas de salud

La cronicidad y multimorbilidad no sólo suponen una carga para los individuos, sino que tienen efectos múltiples sobre los sistemas de salud y la sociedad en su conjunto. Por ejemplo, se estima que las patologías crónicas generan aproximadamente el 80 % de los contactos con el servicio de salud y el 77% del gasto sanitario en el País Vasco (61). Estas cifras son similares a las obtenidas en otros contextos geográficos, tales como Inglaterra (62) e, incluso, menores que las referidas en algunas poblaciones americanas (63). Además, un pequeño número de pacientes pluripatológicos requiere un número tan elevado de hospitalizaciones recurrentes y otros tratamientos costosos que los gastos de su atención suponen la mayor parte de los presupuestos de las organizaciones sanitarias (64).

A pesar de todo ello, la mayoría de los sistemas de salud todavía están organizados según un modelo de atención reactiva y fragmentada en episodios, que puede resultar adecuado para proporcionar cuidados a pacientes agudos, pero que resulta ineficaz en la asistencia a las personas con patologías crónicas y múltiples problemas de salud. El enfoque tradicional de la asistencia se basa en un concepto de enfermedad de inicio brusco, que a menudo puede ser curada por los profesionales sanitarios. Sin embargo, las enfermedades crónicas tienen características muy diferentes. Generalmente, su aparición es gradual, su desarrollo progresivo

y su tratamiento complejo, requiriendo la intervención de diversos niveles de atención sanitaria y la interacción de estos con los servicios sociales. Como consecuencia, estos pacientes tienen que soportar su situación y sus efectos durante un periodo muy prolongado de tiempo (65).

La multimorbilidad, supone una limitación para la calidad de vida, el estado funcional y la productividad de las personas que la sufren y sus familias. Además, la atención sanitaria que reciben con frecuencia resulta escasamente coordinada, lo cual tiene un impacto negativo sobre sus resultados e incrementa sus costes (28,59,66).

La mayor parte de los contactos de los enfermos multimórbidos con los servicios de salud se producen en atención extrahospitalaria. Con respecto a atención primaria, estas personas realizan más visitas (por teléfono, cara a cara en la consulta del médico o a domicilio), visitan a más médicos diferentes, reciben más prescripciones y derivaciones a otros niveles de atención (28,59,67). Así mismo, su número de contactos con atención especializada y número de especialistas distintos visitados es más elevado (28,68,69). Sin embargo, los estudios publicados hasta la fecha muestran diferencias relevantes, atribuibles al menos parcialmente a la organización de los servicios de salud. Mientras que en América los pacientes con mayor comorbilidad visitan con mayor frecuencia a los especialistas y a un número más alto de ellos, pero no a médicos de primaria (68), en Suiza (70) se comprobó un incremento proporcionalmente mayor en atención primaria que especializada, y en Irlanda (28) se describió un aumento en ambos tipos de contactos, manteniéndose la misma proporción entre ellos. Otro hecho interesante es la diferencia en la progresión de visitas en función del número de enfermedades crónicas coexistentes: mientras que Glynn (28) observó una relación lineal, Van Den Bussche (69) encontró también un aumento en función del número de patologías, aunque el mayor incremento tiene lugar entre 0 y 1 patologías y el aumento es bastante más modesto para cada patología añadida. Incluso, Van Oostom (67) explicó que el aumento de

visitas disminuye a medida que van coexistiendo más enfermedades; analizó de manera individualizada a los sujetos que presentaban las 10 patologías más prevalentes y comprobó que el número total de visitas resulta inferior al esperado en función de presencia de las enfermedades por separado.

Con respecto a los servicios hospitalarios, todos los estudios encuentran una asociación positiva entre multimorbilidad y número de ingresos o duración de estancia en el hospital (51,55–57). Aunque resulta difícil generalizar sus resultados, en muchos casos se observa una relación geométrica, según la cual el gasto dobla su cifra por cada enfermedad crónica añadida (66).

La relación entre multimorbilidad y coste de la atención ha sido estudiada en Estados Unidos y en otros países. En función de sus resultados, las personas con pluripatologías deben recibir anualmente unos cuidados sanitarios que resultan entre 4 y 20 veces más caros que los pacientes con una o ninguna enfermedad crónica (59,66,70,71). Mientras que hace dos décadas la mayor parte del incremento en el gasto sanitario era atribuido al desarrollo de unidades de cuidados intensivos, las tendencias actuales nos muestran que la mayor parte de dicho crecimiento es debido a la asistencia proporcionada a un número progresivo de pacientes que conviven con enfermedades crónicas (66). Incluso, tal aumento en prevalencia de multimorbilidad y el coste de su asistencia llegan a suponer una amenaza para la propia subsistencia de los sistemas de salud.

1.1.8 Nuevos modelos de provisión de cuidados sanitarios

Los cambios observados en la carga de enfermedad que presenta la población actual han dejado obsoletos los modelos asistenciales empleados ahora. La cronicidad es un fenómeno emergente a nivel mundial, frente a la cual resultan poco eficaces sistemas que tienen como objetivo principal la curación de enfermedades agudas. Los cambios necesarios suponen, a nivel micro, un enfoque en las personas que conviven con enfermedades crónicas y sus necesidades sanitarias y sociales, impulsando una atención centrada en la persona, en la cual la autogestión de la enfermedad por el propio paciente no debe obviarse. A nivel macro, la cronicidad urge a la completa transformación de los modelos de asistencia sanitaria (14).

Por ello, no resulta sorprendente que en una encuesta a médicos de atención primaria en 11 países de la Organización para la Cooperación y Desarrollo Económicos (OCDE), la mayoría de los médicos de 9 de esos países consideraban que los sistemas de salud en los que trabajaban necesitaban profundos cambios o ser reconstruidos en su totalidad (73). Esta percepción es también compartida por muchos profesionales en el País Vasco (61).

En diversos países se han explorado distintos enfoques prácticos para responder a esta transformación. Muchos de ellos han tomado en consideración el *Chronic Care Model (CCM)* diseñado por Wagner (74). El CCM presenta una síntesis de los cambios en los sistemas que pueden ser usados como una guía para mejorar la calidad de la atención, por medio de interacciones entre pacientes activos e informados y equipos de atención proactivos. Su eficacia y factibilidad de implementación ha sido descrito en algunas revisiones (75,76). Por tanto, aunque dichas estrategias se han aplicado en organizaciones y sistemas de salud de características muy diferentes, comparten algunos rasgos comunes, como son el planteamiento de una asistencia proactiva centrada en el paciente, la continuidad de la

atención, la promoción del autocuidado, el apoyo a la familia y la participación de la comunidad.

Dado que no todas las personas tienen la misma carga de morbilidad, ni requieren el mismo tipo de atención sanitaria, un requisito necesario para que las intervenciones que se planifiquen resulten efectivas es que se ejecuten solamente en aquellos pacientes que respondan al perfil para el que fueron diseñadas. La clasificación de los pacientes en grupos homogéneos en función de su necesidad de atención es el método que habitualmente se emplea para identificar a las personas susceptibles de beneficiarse de tales intervenciones.

1.2 SISTEMAS DE EVALUACIÓN Y AJUSTE DE RIESGOS.

1.2.1 Evaluación y ajuste de riesgo

Los sistemas de ajuste de riesgo (*risk adjustment*) se desarrollaron originariamente en Estados Unidos como herramientas para la financiación y contratación en aseguramiento sanitario. Dadas las diferencias que se observan entre personas en su estado de salud, el coste de la atención resulta muy variable de un individuo a otro. Sin un sistema de ajuste de pago, las organizaciones podrían obtener un gran beneficio si incluyeran sólo a los pacientes más sanos ("*cherry-picking*") y evitaran a los más enfermos ("*cream skimming*") (77). Además, es probable que los pacientes más enfermos se congregaran en la organización que les proporcionase una mejor atención; como consecuencia, ésta se vería obligada a subir el precio de sus primas, lo cual alentaría a sus afiliados a buscar planes más baratos, generándose un círculo vicioso.

Los modelos de ajuste de riesgo tratan de corregir este problema y, mediante su aplicación, se ofrece un pago más alto por la asistencia a una persona con múltiples enfermedades que a otra sana o con menos patologías (78). Funcionando de una manera óptima deberían suprimir el problema de la selección adversa a los pacientes más costosos: precisamente, crearían incentivos a las organizaciones que atienden a los pacientes con mayores necesidades, pues una provisión más eficiente de cuidados les permitiría generar mayores beneficios (79).

La aplicación de ajuste de riesgo precisa de sistemas de información que les ofrezcan predicciones adecuadas y capturen los factores clave que afectarán al coste futuro. La evaluación de riesgos (*risk assessment*) es el método para determinar de manera objetiva si una persona (o grupo de personas) presenta un riesgo razonablemente similar al del promedio

de la población y, en caso contrario, cuantificar la desviación relativa a ese promedio (78). A nivel práctico, los datos se presentan en forma de índice de riesgo (*risk score*): si el riesgo promedio para el conjunto de la población es 1.0, un sujeto joven puede recibir un índice de 0.4, una mujer con asma 1.5 y un anciano con diabetes 2.3. Los índices individuales se agregan en un índice general para la población atendida por cada organización sanitaria. Una organización que tenga un índice agregado de 1.2, como compensación, debería recibir por cada persona a la que atiende un pago 20% por encima del pago promedio, mientras que otra organización con un índice 0.8 obtendría una reducción del 20% en el pago percibido (80).

Si bien no todos los autores emplean una terminología uniforme (81), podríamos considerar que evaluación de riesgos es la metodología que permite predecir cuál será la atención sanitaria que precisará el individuo X.X. en los próximos 12 meses, mientras que ajuste de riesgos consistiría en establecer cuál es la mejor fórmula de pago capitativo que debería recibir una organización sanitaria por atender a X.X. durante el próximo año (78).

Estos sistemas se basan en modelos estadísticos, cuya capacidad para predecir el consumo de recursos sanitarios, hospitalizaciones u otras variables de interés, ha sido evaluada en diversos estudios (81,82). Para que su empleo resulte posible deben requerir solamente aquellas variables explicativas (clínicas, demográficas o coste previo de la atención), cuya obtención resulte factible para toda la población y, por ello, habitualmente utilizan la información ya registrada en las bases de datos administrativas. Los modelos basados en variables clínicas habitualmente ofrecen una capacidad explicativa superior y son más fáciles de comprender e interpretar por los clínicos y gestores, responsables de la atención de estos pacientes. Por otra parte, la inclusión del coste previo de la atención puede resultar cuestionable: si bien esta variable muestra una gran capacidad predictiva (83), se encuentra influenciado por factores distintos de la necesidad de los pacientes, como es la propia eficiencia (o ineficiencia) de los servicios de salud que les atienden.

Aunque el ajuste de riesgos para establecer un pago capitativo más equitativo se ha utilizado principalmente en Estados Unidos (79,81,85,86), también existen algunas experiencias de su empleo en Europa (87) y otros lugares (88). Sin embargo, además de contribuir a una financiación más equilibrada de las organizaciones sanitarias, esta metodología ha despertado gran interés para otras aplicaciones, como instrumento de ajuste al comparar los indicadores de la calidad de asistencia sanitaria obtenidos por distintos proveedores (89–91) o para identificar prospectivamente a las personas cuya atención resultará especialmente costosa (83,92–94). En este sentido, una experiencia muy simple pero ilustrativa es la que realizó Ellis (81). En septiembre de 2006 introdujo la expresión “*risk adjustment*” AND “*health*” en el buscador Google, obteniendo 259.000 respuestas. De ellas, la palabra “*payment*” apareció en el 45% de las páginas web, mientras que la palabra “*quality*” estuvo presente en el 73%.¹ Muchos indicadores empleados para medir la calidad de la atención implican una mezcla de factores propios del paciente y del proveedor. Con frecuencia los pacientes con enfermedades más complejas obtendrán peores resultados que los sujetos sanos, incluso aunque reciban unos cuidados sanitarios de mayor calidad. Por ello, cuando se les presentan sus evaluaciones, los médicos que obtienen peores resultados, sin duda, responderán: “...pero tenga en cuenta que mis pacientes están más enfermos”. Los sistemas de evaluación y ajuste de riesgo ayudarán a determinar qué parte de las diferencias observadas se puede atribuir a las características de los pacientes (es decir, escapan al control del médico) y qué parte es imputable a la calidad de la atención sanitaria que se le ha proporcionado. (95)

¹ En febrero de 2016 nosotros repetimos esta búsqueda en Google, con unos resultados similares: “*risk adjustment*” AND “*health*” en 483.000 páginas web; “*risk adjustment*” AND “*health*” AND “*quality*” en 356.000 (74%); “*risk adjustment*” AND “*health*” AND “*payment*” 177.000 (37%).

1.2.2. Limitaciones de los modelos estadísticos para evaluación de riesgos

Los sistemas habitualmente empleados presentan algunas limitaciones, muchas de ellas comunes a todos ellos. Como ya se ha señalado, se basan en un número limitado de variables explicativas. Por ello, quedan excluidos de estos modelos algunos factores que se sabe influyen en la necesidad de atención sanitaria o los resultados de la misma; entre otros están los psicosociales, los relativos al entorno cultural y socioeconómico, los hábitos y conductas de riesgo, la autopercepción de salud, calidad de vida o actitudes y preferencias de los pacientes (96,97).

Por otra parte, para estimar el estado de salud de las personas, solo tienen en cuenta las enfermedades y problemas por los que las personas han buscado atención sanitaria, esto es, por los que han contactado con los servicios de salud; por lo tanto, aquellas necesidades no percibidas pudieran no ser tenidas en cuenta. Asimismo, los grupos sociales que encuentren barreras que dificulten su acceso quedarían insuficientemente evaluados.

En tercer lugar, es sabido que los registros en los sistemas de información sanitaria o historias clínicas electrónicas pueden ser inexactos o contener errores. De hecho, en algunos estudios han comprobado que la inclusión complementaria de diversos métodos para detectar las patologías de las personas consigue una mejor descripción de la morbilidad de la población (98).

1.2.3 Empleo de los modelos de ajuste de riesgo en nuestro medio

Como se ha descrito, la aplicación de estos métodos es común en organizaciones de otros países. Sin embargo, su empleo en sistemas nacionales de salud y, en concreto, en nuestro

país, ha sido hasta ahora muy limitado. En nuestro medio, se han realizado trabajos de investigación que han comprobado su validez (99–101).

Así, en el País Vasco se comprobó la validez del *case-mix* Adjusted Clinical Groups (102) para explicar de manera retrospectiva el consumo de recursos sanitarios, determinándose que este sistema puede explicar más del 50% de la variabilidad en el número de vistas al médico de atención primaria, entre el 25 y 40% en prescripciones, de 25 a 30% en derivaciones a atención especializada y peticiones de pruebas de laboratorio y entre 14 y 16% en exploraciones radiológicas en circunstancias de práctica habitual (103). En otros lugares de España algunos autores han realizado trabajos con *Diagnostic Cost Groups/Hierarchical Condition Categories* (DCG-HCC) (104) y *Clinical Risk Groups* (CRG) (105). Inoriza empleó CRGs para describir la carga de morbilidad en la población atendida en una organización sanitaria integrada en Cataluña (100) y García-Goñi estudió su capacidad para explicar el consumo en prescripciones y su aplicabilidad para la financiación e identificación de los proveedores más eficientes (101). Sin embargo, sólo existen unas pocas experiencias de su uso más allá del ámbito académico (106).

1.3 IMPLANTACIÓN DEL PROGRAMA DE ESTRATIFICACIÓN POBLACIONAL EN EL PAIS VASCO.

RESULTADOS EN EL PRIMER AÑO

1.3.1 Seleccionando pacientes para realizar intervenciones en el País Vasco

El Programa de Estratificación Poblacional (107) se puso en marcha en el País Vasco como parte de la “Estrategia para afrontar el reto de la cronicidad en Euskadi” (108). Esta estrategia definió un modelo más proactivo, integrado, preventivo y enfocado en las necesidades de la población. Estaba dividida en 5 áreas de cambio: adopción de un enfoque poblacional; promoción y prevención de las enfermedades crónicas; responsabilidad y autonomía del paciente; continuidad asistencial para el enfermo crónico; e intervenciones eficientes adaptadas a las necesidades del paciente, y se desarrolló por medio de 14 proyectos estratégicos, uno de los cuales fue la estratificación poblacional.

Desde 2005 Osakidetza venía empleando un sistema de *case-mix* (ACG) para observar la distribución de morbilidad atendida en la población y para evaluar la eficiencia de los profesionales sanitarios. Sin embargo, hasta entonces sólo se había recurrido a modelos retrospectivos, empleando exclusivamente los diagnósticos realizados por los médicos de atención primaria (109).

Para poner en marcha de la Estrategia de la Cronicidad se comprobó la necesidad de contar con un modelo prospectivo de estratificación de la población en función de sus futuras necesidades asistenciales. Por ello, se implantó el Programa de Estratificación. Su objetivo era proporcionar al Sistema Sanitario Vasco instrumentos para seleccionar a las personas que, por sus características demográficas, clínicas, sociales y el coste previo de su atención sanitaria, fueran candidatos para intervenciones y programas específicos que se diseñaran. Para ello, se

clasificó a toda la población de la CAPV, combinando diferentes todas las fuentes de información de hospitales y atención primaria.

1.3.2 Procedimientos de clasificación

En el primer año de funcionamiento del Programa se procedió a clasificar a todos los habitantes del País Vasco asignados a un médico de Osakidetza durante un mínimo de 6 meses, en el periodo comprendido entre el 1/09/2009 y el 31/08/2010 (n = 2.292.581).

1.3.2.1 Fuentes de información.

Como fuentes de información se emplearon el Conjunto Mínimo Básico de Datos (CMBD) de hospitales y datos extraídos de las historias clínicas informatizadas de atención primaria.

El CMBD (110) contiene información de los pacientes ingresados en los hospitales. En cada ingreso (episodio de hospitalización) en esta base de datos se registran de un modo estandarizado las siguientes variables (111):

- Correspondientes a identificación del paciente. Contiene, entre otras, las demográficas (fecha de nacimiento y sexo).
- Relativas al episodio, como por ejemplo, fecha de ingreso y alta.
- Variables clínicas, como son el diagnóstico principal (motivo de ingreso), comorbilidad (diagnósticos secundarios) y procedimientos. Existe personal especializado que se encarga de su codificación mediante Clasificación Internacional de Enfermedades, en su versión modificación clínica (CIE-9-MC) (112).

Osabide es la historia clínica informatizada (HCI) empleada por Osakidetza. Fue diseñada para facilitar la atención individual al paciente durante su contacto con el médico. Los problemas de salud de los pacientes se organizan en episodios de atención (113), definidos como la serie de servicios proporcionados en respuesta a un problema de salud del paciente u otra razón especificada (p. ej., un procedimiento preventivo), desde su primer contacto con los servicios de salud hasta la finalización del último contacto provocado por ese motivo, según el criterio del médico visitado. Las anotaciones que los médicos realizan en las HCI pueden ser en forma de texto o mediante un formulario se asocian con un episodio. Los propios clínicos, cuando establecen o modifican el diagnóstico de un episodio, deben introducir su correspondiente código CIE-9-MC. Las prescripciones efectúan mediante de los formularios de receta electrónica y la codificación de tales fármacos mediante el sistema *Anatomical Therapeutic Chemical (ATC) Classification System* (114) se realiza de manera automática por la Subdirección de Asistencia Sanitaria de Osakidetza. Una descripción más detallada ha sido ya publicada (115).

1.3.2.2 Datos incluidos

Para clasificar a los pacientes se utilizaron los siguientes datos: edad, sexo, códigos CIE-9-MC de los diagnósticos, códigos ATC de los fármacos prescritos, necesidad de tratamiento crónico con diálisis y número de hospitalizaciones que presentaron durante los 12 meses observados.

Se consideraron diagnósticos de atención primaria los de los episodios en los cuales algún médico realizó alguna anotación. Con el fin de evitar la posible inclusión de patologías de curso prolongado, pero que no están activas en el momento actual, solo se tomaron en consideración las enfermedades consideradas motivo de consulta durante el periodo de observación, según los registros de los médicos en las historias de primaria. Las prescripciones

corresponden a los formularios que al efecto se rellenaron en Osabide. Los diagnósticos de hospital comprenden tanto los principales como los secundarios, según consta en el CMBD.

1.3.2.3 Case-mix

El *ACG Predictive Modelling* (ACG-PM) es un instrumento de estratificación poblacional, diseñado para predecir el coste sanitario, gasto en farmacia y riesgo de hospitalización. Emplea variables demográficas (edad y sexo), información clínica registrada durante 12 meses (códigos de los diagnósticos, fármacos o ambos) y, opcionalmente, datos sobre utilización de servicios y costes previos (102).

1.3.2.4 Clasificación de diagnósticos

Para incorporar la información procedente de diagnósticos, el programa ACGrouper realiza diferentes agrupaciones (Figura 1):

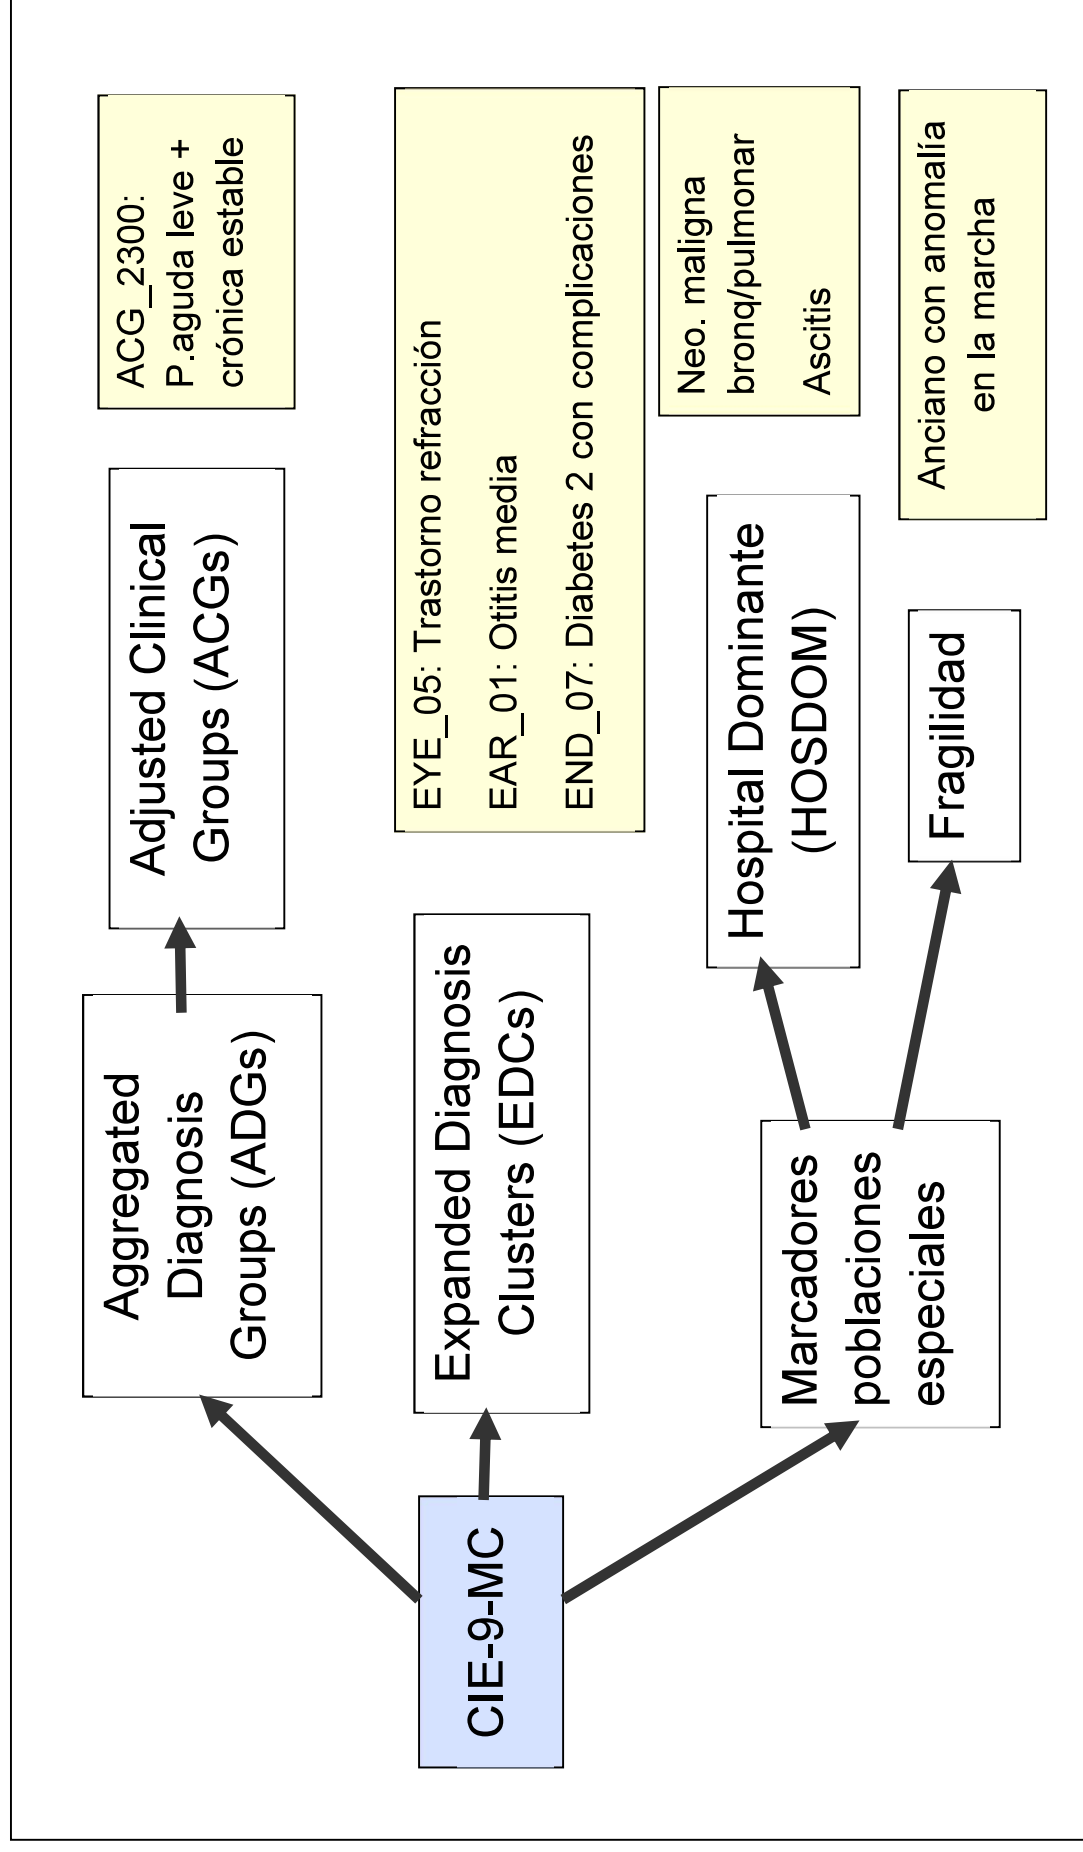
- ACGs: son categorías autoexcluyentes de pacientes, creadas a partir de su comorbilidad. En un primer paso los diagnósticos asignados durante 12 meses son clasificados en 32 grupos, llamados *Aggregated Diagnostic Groups* (ADGs) en función de la probable duración o recurrencia de ese problema de salud y el consumo de recursos esperado para su tratamiento. A partir de su combinación de ADGs, edad y sexo, cada persona es clasificada anualmente en un único ACG.
- Los *Expanded Diagnosis Clusters* (EDCs) constituyen un modo diferente de clasificar los diagnósticos, basado en criterios exclusivamente clínicos. Permiten identificar a las personas que presentan una patología determinada.

- *Hospital Dominant Conditions* (patologías determinantes de hospitalización) son enfermedades cuyo diagnóstico implica un riesgo de hospitalización superior al 50% el año siguiente.
- Marcador de Fragilidad: es una variable dicotómica que indica la presencia de algún problema médico asociado a esta situación.

1.3.2.5 Identificación de problemas de salud a partir de las prescripciones

El sistema ACG-PM emplea también la información procedente de las prescripciones para conocer la morbilidad de las personas. Para ello, los fármacos (clasificados en el sistema ATC) se agrupan en 64 *Rx-Morbidity Groups* (Rx-MGs) a partir de cuatro criterios: sistema corporal al que se dirigen, nivel de especificidad, duración esperada y gravedad.

Figura 1: Grupos generados por el sistema ACG-PM para clasificar diagnósticos y algunos ejemplos.



1.3.2.6 Desarrollo del modelo predictivo

La Figura 2 resume las variables utilizadas y las estimaciones que ofrece el *case-mix*. La predicción del consumo de recursos se presenta en forma de índice (expresado como peso relativo y corresponde al cociente de dividir el gasto esperado en ese paciente entre el promedio de la población). El software ACG-PM clasifica por separado a la población en dos grupos de edad: mayores y menores de 65 años. La tabla 1 muestra algunos ejemplos de pacientes y el índice predictivo obtenido a partir de sus patologías.

Figura 2: Variables incluidas por el modelo predictivo ACG-PM

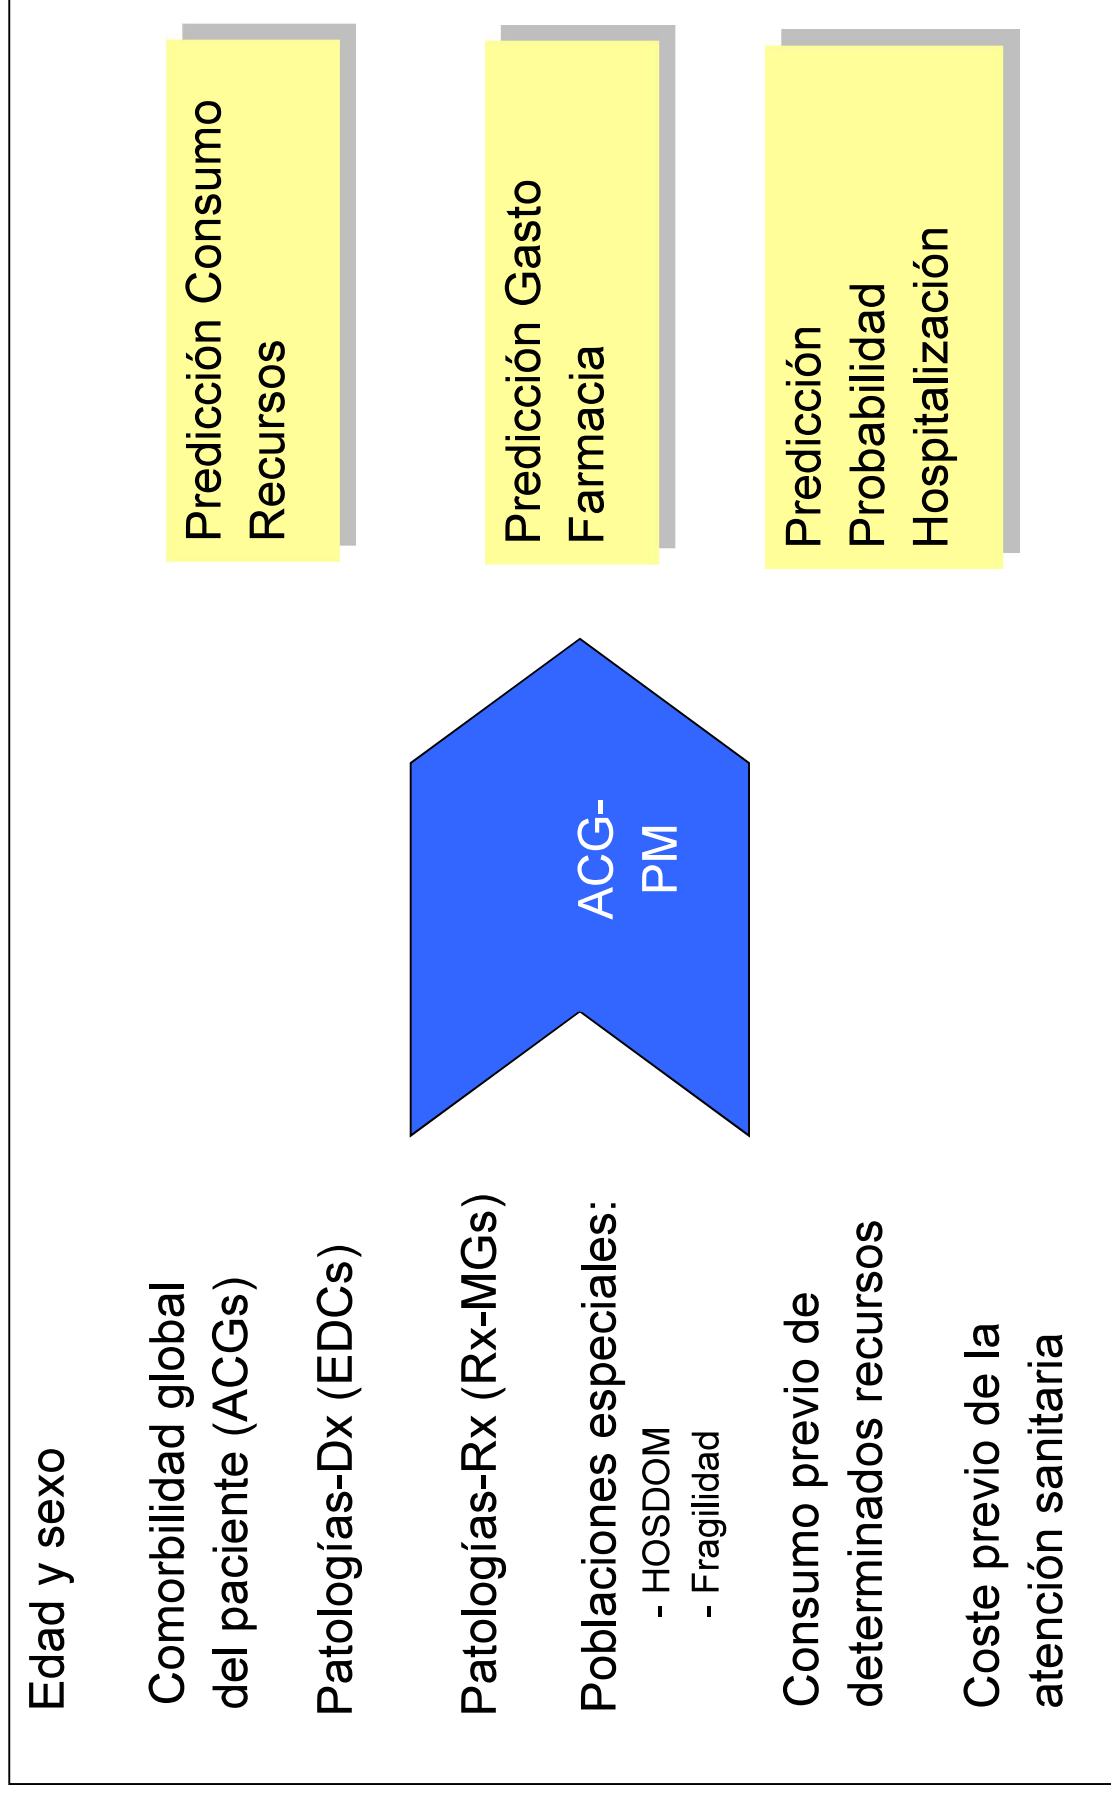


Tabla 1. Ejemplos de pacientes clasificados según el modelo de estratificación poblacional aplicado en el País Vasco

Edad	Sexo	Ingresos año previo	Problemas de salud identificados por diagnósticos	Problemas de salud identificados a partir de prescripciones	Índice Predictivo
8	Hombre	0	Infección aguda de Tracto Respiratorio Superior Esguinces y lesiones agudas	Enf. Leve de Sistema Respiratorio	0,04
23	Mujer	0	Gastroenteritis Atención Preventiva	NO	0,27
55	Hombre	0	Atención Preventiva Síntomas y signos inespecíficos	NO	0,75
55	Mujer	0	Hipertensión arterial sin complicaciones Otros Trastornos Endocrinológicos Síntomas y signos del S. Musculoesquelético Hiperlipidemia Infección aguda de Tracto Respiratorio Superior Atención Preventiva	Depresión Hipertensión arterial Enf. Dermatológica Recurrente Enf. Leve de Sistema Respiratorio Dolor e Inflamación	2,05
87	Hombre	0	Neoplasia Maligna de Próstata Tromboflebitis Hiperlipidemia Síntomas y signos inespecíficos Tapón de Cerumen Atención Preventiva	Neoplasia Maligna Dolor Enfermedad Cardiovascular Crónica Trastornos Vasculares Hipertensión arterial Enfermedad Respiratoria Crónica Enfermedad Péptica Dolor e Inflamación Hiperlipidemia	7,31

Tabla 1 (continuación). Ejemplos de pacientes clasificados según el modelo de estratificación poblacional aplicado en el País Vasco

Edad	Sexo	Ingresos año previo	Problemas de salud identificados por diagnósticos	Problemas de salud identificados por prescripciones	Índice Predictivo
59	Hombre	0	Insuficiencia Renal Crónica Cardiopatía Isquémica Colecistitis, Colelitiasis Úlcera Péptica	Diabetes Mellitus no insulinodependiente Hipertensión arterial Trastornos vasculares Enfermedades Oseas Gota Enfermedad Péptica Dolor e Inflamación Infecciones Leves Hiperlipidemia	8,58
87	Mujer	1	Insuficiencia Renal Crónica Nefritis, Nefrosis Diabetes tipo2 con complicaciones Enfermedad Valvular Cardiaca Arritmia Cardiaca Hiperlipidemia Hipertensión Arterial con complicaciones Gota Enfermedad Diverticular del Colon Otros Trastornos Endocrinológicos Colecistitis, Colelitiasis Artrosis Síntomas y signos del S. Musculoesquelético Dermatitis, eczema Síntomas y signos inespecíficos Infección Respiratoria Aguda Atención Preventiva	Diabetes Insulinodependiente Enf. Crónica de Sistema Nervioso Enf. Crónica de Sistema Respiratorio Hipertensión Arterial Gota Enfermedad Péptica Hiperlipidemia Enf. Dermatológica Recurrente Dolor Infecciones Leves Enf. Leve de Sistema Respiratorio	13,79

Tabla 1 (continuación). Ejemplos de pacientes clasificados según el modelo de estratificación poblacional aplicado en el País Vasco

Edad	Sexo	Ingresos año previo	Problemas de salud identificados por diagnósticos	Problemas de salud identificados por prescripciones	Índice Predictivo
56	Mujer	1	Estado Post-Trasplante Neoplasia Maligna de Alto Impacto Insuficiencia Renal Crónica Alteraciones de la retina Convulsiones Nefritis, Nefrosis Hipertensión arterial con complicaciones Trastornos Gastrointestinales/Hepáticos Anemia Ferropénica Otros trastornos Hematológicos Síntomas y signos del S. Nervioso Síntomas y signos inespecíficos Hiperlipidemia Exantema	Insuficiencia Cardíaca Congestiva Dolor Enfermedades Oseas Trastornos Vasculares Enfermedad Péptica Hiperlipidemia Dolor e Inflamación Otras Medicaciones	39,81

Nota: El índice predictivo (IP) expresa el cociente de dividir el gasto esperado en paciente determinado entre el promedio de la población. Por ejemplo, la persona de la segunda fila tiene un IP de 0,27 (es decir, se espera que sólo necesite cuidados sanitarios cuyo coste equivalga al 27% del paciente promedio) mientras que la presentada en la sexta fila presenta un IP de 8,58 (o sea, el equivalente a multiplicar el coste del paciente promedio por 8,58).

1.3.3 Resultados y aplicaciones de la clasificación de pacientes

Del total de personas observadas, 1.165.649 (50,8%) fueron mujeres y el promedio de edad fue 43,7 años. El porcentaje de niños fue de 12,3% y el de personas mayores de 65 años 19,7%.

El 72,3% de la población realizó al menos una visita al médico de atención primaria y el 7,8% presentó una o más hospitalizaciones, contabilizándose 243.218 ingresos.

1.3.3.1 Agrupación de diagnósticos y medicaciones

El total de diagnósticos fue 23.964.758 y de ellos, un 3,3% procedían del CMBD de hospital. Se incluyeron 20.451.887 prescripciones, realizadas por los médicos de atención primaria a las personas que les consultaron y que suman un total de 1.497.195 pacientes; de ellos 50.857 (3,4%) no contaban con diagnóstico alguno. Como cabía esperar, el empleo conjunto de la información procedente de diagnósticos y prescripciones permite identificar un número más alto de enfermos crónicos que utilizando estas fuentes por separado (Tabla 2).

Tabla 2.- Comparación de las prevalencias obtenidas en algunas patologías, empleando como fuente de información diagnósticos o prescripciones.

Descripción	Diagnósticos		Prescripciones		Cualquiera	
	N	%	N	%	N	%
Artritis Reumatoide	5.503	0,24%	9.289	0,41%	12.665	0,55%
Asma persistente	100.554	4,39%	167.233	7,29%	181.034	7,90%
Convulsiones	8.616	0,38%	44.443	1,94%	46.762	2,04%
Depresión	26.397	1,15%	137.024	5,98%	143.279	6,25%
Diabetes	97.978	4,27%	90.950	3,97%	115.027	5,02%
Glaucoma	16.964	0,74%	43.286	1,89%	46.347	2,02%
Hipertensión	223.524	9,75%	356.661	15,56%	381.601	16,65%
Hipotiroidismo	37.702	1,64%	47.337	2,06%	60.542	2,64%
Inmunosupresión/Trasplante	1.405	0,06%	4.042	0,18%	4.267	0,19%
Insuficiencia Cardíaca congestiva	12.731	0,56%	68.480	2,99%	70.202	3,06%
Insuficiencia Renal Crónica	15.688	0,68%	645	0,03%	15.853	0,69%
Osteoporosis	29.107	1,27%	95.432	4,16%	102.240	4,46%
Parkinson	4.147	0,18%	9.041	0,39%	9.784	0,43%
Trastorno del Metabolismo de Lípidos	171.290	7,47%	225.369	9,83%	299.112	13,05%

1.3.3.2 Estratificación de los pacientes y aplicaciones en el País Vasco

Con la información recopilada se obtuvo el índice predictivo de consumo de recursos de cada paciente que ofrece por defecto el programa informático, el cual, junto con el resto de variables que proporciona el sistema ACG-PM, comenzó a ser empleado para identificar a pacientes candidatos a intervenciones específicas, de las que se presentan tres ejemplos:

A) Nuevos roles de enfermería: Enfermera Gestora de Competencias Avanzadas.

Con el objetivo de conseguir una mejor adaptación de las labores de enfermería a las necesidades de los pacientes crónicos, en el País Vasco se pilotaron diferentes figuras. Uno de tales roles fue el de enfermera de competencias avanzadas para la gestión de casos complejos. Sus funciones eran coordinar, gestionar y unificar la atención sanitaria, así como proporcionar cuidados clínicos avanzados y personalizados en pacientes vulnerables en su domicilio. Cada una contaba con un listado de unos 50 usuarios, identificados, entre otras, a través de las herramientas de estratificación.

Las poblaciones diana se obtuvieron en función de las características propias de las Comarcas de Atención Primaria (CAP) y la coexistencia en ellas de otros programas específicos. Los criterios empleados fueron:

- La probabilidad del paciente de presentar un consumo muy elevado de recursos.
- La presencia o ausencia de determinados problemas de salud.
- El número de hospitalizaciones el año previo.

En la Tabla 3 se resumen las selecciones realizadas en 3 CAP.

Tabla 3: Selección de pacientes para Enfermera Gestora Competencias Avanzadas.

Comarca Uribe	
Población Total : 223.681	
Criterios de selección	
Problemas de salud	
Motivos de inclusión	Insuficiencia Cardíaca Congestiva o EPOC
Motivos de exclusión	Ninguno
Predicción necesidad atención sanitaria	
Edad 0-64: IPR>10	
0-1 Ingreso año previo	51
2+ Ingresos año previo	82
Total	133
Edad 65+: IPR> 6	
0-1 Ingreso año previo	26
2+ Ingresos año previo	75
Total	101

IPR: Índice Predictivo de Consumo de Recursos Sanitarios.

Tabla 3: continuación

Comarca Araba			
Unidades de Atención Primaria: 47047; 5002; 5003; 5005; 5008; 5011; 5016			
Población total : 146.932			
Criterios de selección			
Problemas de salud			
Motivos de inclusión	HOSDOM: 1+		
Motivos de exclusión	Insuficiencia Cardíaca Congestiva, Neoplasia, Diálisis crónica o Inmunosupresión		
Predicción necesidad atención sanitaria			
Edad 0-64: IPR>9			
No ingresos año previo	3	No ingresos año previo	25
1+ Ingresos año previo	41	1+ Ingresos año previo	21
Total	44	Total	46

IPR: Índice Predictivo de Consumo de Recursos Sanitarios.

HOSDOM: Problema de salud determinante de hospitalización.

B) Batera-Zainduz: Compartiendo cuidados en la atención al paciente con diabetes mellitus.

En la Unidad de Atención Primaria de Gorliz-Plencia (Bizkaia) se pilotó un proyecto para mejorar la atención a los enfermos con diabetes tipo 2 (Tabla 4). Dicha intervención se fundamentaba en:

- Enfatizar las actividades de autocuidado, en especial en los enfermos con escasa comorbilidad.
- Una mayor implicación de los profesionales en la atención a los enfermos con un grado más alto de complejidad. Para ello, se puso en marcha un call-center que periódicamente contacta con el paciente para evaluar su situación, detectar aspectos relacionados con el cumplimiento y servir de refuerzo del tratamiento.
- En los pacientes con mayor riesgo, se realizó una evaluación, plan individualizado y seguimiento compartido del paciente entre el médico de atención primaria y el endocrinólogo de referencia.

Se siguieron los criterios de un estudio previo dirigido por investigadores de la Universidad Johns Hopkins (116), estratificando los pacientes en tres grupos.

- Se consideraron pacientes de mayor riesgo los que presentaban un mal control de su patología (por sus valores de hemoglobina glicosilada [HbA1c] superior a 9%) o aquellos que, aun estando bien controlados, su tratamiento podía resultar difícil por la presencia de comorbilidad (en función de índices predictivos superiores a 7,5; esto es, su consumo esperado de recursos en el año siguiente multiplicaba por más de 7,5 el del paciente promedio).

- Situación intermedia si HbA1c entre 7,5% y 9% o índice predictivo entre 3,2 y 7,5.
- Riesgo bajo, pacientes con diabetes mellitus bien controlada (HbA1c inferior a 7,5%) y carga de morbilidad no elevada (índice predictivo inferior a 3,2).

Tabla 4: Estratificación pacientes con diabetes mellitus.

Unidad de Atención Primaria : Gorliz-Plencia		
Población total : 8.907		
Grupo 3	HbA1c > 9 o IPR > 7,5	42 (14%)
Grupo 2	HbA1c 7,5-9 o IPR: 3,2 - 7,5	101 (35%)
Grupo 1	HbA1c < 7,5 y IPR < 3,2	149 (51%)
Total		292

IPR: Índice Predictivo de Consumo de Recursos Sanitarios.

C) Aplicación en la evaluación de la Oferta Preferente

La Oferta Preferente de Servicios Sanitarios (OP) es una herramienta que emplea Osakidetza para la evaluación y financiación de las CAP. Incluye los servicios priorizados por el Plan de Salud y sus intervenciones se fundamentan en GPC.

Como ya se ha citado con anterioridad, puede resultar problemático ajustar las recomendaciones de las GPC a las personas con múltiples patologías (43,44). Además, muchas de sus recomendaciones se refieren a actividades de prevención secundaria y terciaria, cuyos beneficios serán más notables en los pacientes en estadios iniciales y con escasa comorbilidad.

Por ello, la Subdirección de Asistencia Sanitaria de Osakidetza inició la adopción progresiva de un enfoque poblacional en la OP, que se adecuase a las necesidades específicas de los diferentes grupos de pacientes. Por este motivo se priorizó la realización de actividades de prevención secundaria en pacientes con diabetes tipo 2, HTA e hipercolesterolemia. Se consideró como enfermos con comorbilidad o complicaciones relevantes (esto es, excluidos de esta intervención) a los que además presentan insuficiencia cardíaca, cardiopatía isquémica o un determinado índice predictivo (Tabla 5).

Tabla 5. Oferta preferente: selección de pacientes crónicos con escasa comorbilidad

Criterios de inclusión:
Presencia de alguno de estos 3 diagnósticos:
Diabetes tipo-2
HTA
Hiperlipidemia
Predicción necesidad atención sanitaria
Edad 0-64: IPR < 2,7
Edad 65+ : IPR < 1,5
Criterios de exclusión:
Presencia de alguno de estos 2 diagnósticos:
Insuficiencia cardíaca
Cardiopatía Isquémica

IPR: Índice Predictivo de Consumo de Recursos Sanitarios.

1.3.4. Lecciones aprendidas a partir de la aplicación de la estratificación poblacional en el País

Vasco

La experiencia descrita permitió comprobar que la adopción de un enfoque poblacional, combinado con una explotación exhaustiva de la información sanitaria disponible, nos ofrece orientaciones sobre el modo de dirigir nuestros esfuerzos para mejorar la atención a los pacientes crónicos. Así, la utilización conjunta del CMBD de hospitales y los diagnósticos y prescripciones de las HCI de atención primaria, registrados en condiciones de práctica habitual, permitió estratificar prospectivamente a la población e implantar intervenciones específicas, diseñadas en función de las necesidades de atención de cada grupo poblacional definido.

Sin embargo, también se observaron dificultades en el desarrollo, aplicación y uso generalizado de la estratificación poblacional en el País Vasco. De hecho, en algunos lugares los profesionales sanitarios (gestores y clínicos) no fueron capaces de comprender correctamente los modelos predictivos y, en vez de ellos, emplearon escalas o índices de comorbilidad ajenos al Programa de Estratificación. Estas escalas estaban basadas únicamente en criterios clínicos, cuya validez estadística para predecir el consumo de recursos u otras variables nunca se comprobó. La utilización simultánea de instrumentos tan diferentes para identificar poblaciones diana generó desconcierto y dificultó la evaluación del programa de estratificación y sus aplicaciones.

1.4 DIFUSION DE LA ESTRATIFICACIÓN EN EL MUNDO REAL: EL PUNTO DE VISTA DE LOS CLÍNICOS.

Existe una gran cantidad de bibliografía que describe iniciativas desarrolladas para mejorar la calidad de la atención sanitaria y se han diseñado modelos que identifican los factores clave para alcanzar el éxito (117). Sin embargo, las dificultades para implantar una nueva tecnología en los servicios de salud son numerosas y el proceso puede ser lento y tortuoso. Berwick (118) proporciona ejemplos ilustrativos de la enorme distancia existente entre el conocimiento científico y la práctica clínica habitual, del ritmo lento en que se traslada dicho conocimiento y de las barreras que se presentan para que las ideas innovadoras sean adoptadas. Incluso, los retrasos y demoras que se toleran en los servicios de salud respecto a la incorporación de tratamientos efectivos (o abandono de otros inefectivos) son superiores a los que se consideran aceptables en otros sectores. Otros autores han reflexionado sobre la falta de permeabilidad al cambio de algunos grupos y las complejas dinámicas creadas en las organizaciones multiprofesionales, como son las sanitarias (119); en ellas, el flujo a través del cual se diseminan la prácticas innovadoras con frecuencia no es lineal, sino errático, circular o sufre cambios bruscos que pueden llevar a su interrupción o, incluso, marcha atrás.

Respecto a la estratificación poblacional, las descripciones del proceso de implantación y los resultados de la misma son menos numerosos. Por otra parte, la exclusiva aplicación de un instrumento de estratificación a una población no tiene efectos per se y siempre va acompañada de programas de intervención en las poblaciones identificadas, lo que dificulta su evaluación individualizada (120). Como consecuencia, la medida del éxito en la implantación de un programa de estratificación en una organización sanitaria resulta enormemente difícil.

El empleo de técnicas de investigación cualitativa puede proporcionar un método válido para identificar las barreras y elementos facilitadores en este proceso. La participación y colaboración de los clínicos se percibe como un elemento clave (120). Aunque se ha comprobado que el empleo de

modelos estadísticos ofrece predicciones más acertadas que las obtenidas a partir de las percepciones de los clínicos, con frecuencia estos últimos son reacios a aceptar los resultados de las herramientas de estratificación y consideran que la selección de los pacientes deben basarse en las opiniones de los profesionales que les atienden (121). Freund (122) propuso un método mixto que combinaba ambos enfoques: los pacientes se seleccionaban mediante modelos estadísticos, pero su inclusión definitiva en un nuevo programa de atención debía ser corroborada por la opinión de los clínicos. Los tres criterios fundamentales para la valoración de los clínicos eran la disposición del paciente a participar en dicho nuevo programa, su capacidad para hacerlo y que las necesidades del paciente resultaran manejables. Aunque este enfoque fue aceptado de buen grado por los médicos participantes en ese estudio, su aplicación plantea dudas muy serias desde el punto de vista de la equidad de la atención: los médicos consideraban razonable excluir a pacientes que carecieran de apoyo familiar, presentaran problemas de abuso de sustancias o dificultades con el idioma, ya que resulta previsible que la colaboración de tales personas sea baja. Así, aunque la inclusión de criterios no clínicos pueda generar mejores resultados, este planteamiento resulta muy cuestionable desde el punto de vista de la justicia social (106). Otro estudio cualitativo realizado en Escocia (123) comprobó que los patrones de distribución de la información procedente de los instrumentos de estratificación son complejos y variables e, incluso, existe el riesgo de que su diseminación no alcance a los usuarios finales. Porter (124) realizó un estudio basado en cuatro grupos focales de profesionales de atención primaria (médicos, enfermeras y gestores). Los participantes veían la estratificación como un elemento de apoyo al juicio clínico y no una sustitución del mismo; también lo consideraban como algo añadido a su trabajo habitual, pero no como una parte fundamental del mismo; aunque el modelo de estratificación evaluado clasificaba a toda la población, los participantes limitaban su discurso casi exclusivamente en la identificación de los pacientes de más alto riesgo; por último mostraban dudas de su utilidad, en el sentido de que sólo identificara a pacientes de alto riesgo que ya eran conocidos por los profesionales que les atendían o que descubrieran pacientes cuya situación

podiera ser de alto riesgo, pero a los cuales no podía ofrecerse un tratamiento efectivo. Los profesionales no ofrecían un relato coherente, sino una mezcla de actitudes, como son escepticismo, ansiedad e incertidumbre, pero también una disposición de mente abierta para aceptar nuevas ideas.

A modo de resumen, se puede concluir que se ha comprobado cómo los modelos estadísticos predictivos muestran una capacidad muy superior a la opinión de los clínicos para identificar a los pacientes en situación de riesgo (125). El conocimiento que tienen los clínicos de sus pacientes les permite seleccionar a los que están en una situación de riesgo elevado en el momento presente, pero no a los que lo estarán en el futuro (126) y, de hecho, las predicciones basadas en opiniones de médicos, enfermeras y gestores no obtienen mejores resultados que la obtenidas simplemente en base al azar (127). Sin embargo, estos hechos no son aceptados con frecuencia por los clínicos, pues contradicen sus percepciones intuitivas. Como consecuencia, la aplicación de la estratificación poblacional en las organizaciones sanitarias se ve obstaculizada por la resistencia de los profesionales.

1.5 ÍNDICES DE COMORBILIDAD

A diferencia de los modelos estadísticos arriba mencionados (como por ejemplo, los que sirvieron de base al Programa de Estratificación del País Vasco) existen otros métodos más simples para medir la comorbilidad. Aunque en principio fueron diseñados para predecir la mortalidad en pacientes a partir de datos administrativos obtenidos de los informes de alta de hospital (128–130) o formularios cumplimentados por los propios clínicos (131) también se han empleado con otros fines. Así, en atención primaria se han usado como medida de multimorbilidad (132) o para predecir costes de la atención (133,134).

El sistema más difundido es el índice de comorbilidad de Charlson, que se basa en los problemas de salud incluidos en un listado. Dicho listado sólo tiene en cuenta las enfermedades crónicas (esto es, excluye las que previsiblemente se resuelvan sin secuelas) y en su versión original incluía 19 patologías. No todas ellas son consideradas equiparables, sino que cada una ellas recibe un peso, cuyos valores son 1, 2, 3 ó 6. El cálculo del índice de un paciente es muy sencillo: basta con sumar los valores de las enfermedades que presenta. El índice de Charlson fue descrito por primera vez en 1987 (128) y un excelente resumen de las modificaciones que ha presentado a lo largo del tiempo ha sido publicada por la Universidad de Manitoba (135).

Con el objetivo de predecir mortalidad en pacientes pluripatológicos, en España se ha desarrollado el índice Profund. Contiene solamente 9 ítems, e incluye parámetros relativos a variables demográficas, clínicas, resultados de laboratorio, grado de discapacidad, apoyo familiar y hospitalizaciones previas.

Aunque la capacidad predictiva de estos sistemas es menor que la de los sistemas de *case-mix* citados en apartados anteriores, por su economía y simplicidad pueden resultar atractivos para los clínicos y los gestores. Por otro lado, presentan otros problemas como son: su visión parcial del paciente, al no tener en cuenta más que un grupo reducido de patologías para su cálculo; el

requerimiento en algunos de ellos de información distinta a la habitualmente contenida en las bases de datos administrativas (131); y su diseño para ser empleados solamente en pacientes que han contactado con los servicios de salud (habitualmente tras una hospitalización), por lo que no son una auténtica herramienta de estratificación poblacional.

1.6 DISEÑO DE UN NUEVO SISTEMA DE ESTRATIFICACIÓN POBLACIONAL EN EL PAÍS VASCO.

Como se ha indicado en los anteriores apartados, los sistemas de información sanitaria del Servicio Vasco de Salud han alcanzado un amplio desarrollo en los últimos años. La implantación de un modelo unificado de historia clínica informatizada en toda la red de atención primaria ha permitido desde 2005 la utilización de un sistema de *case-mix* de base poblacional. Con ello, resulta factible evaluar la eficiencia de los profesionales sanitarios a partir de modelos estadísticos retrospectivos (109). Además, desde la puesta en marcha del Programa de Estratificación Poblacional se cuenta con una base de datos de gran riqueza, que combina información procedente de los sistemas informatizados de atención primaria, especializada y CMBD de hospitales. Aparte de su uso primordial (servir de apoyo a la planificación de la atención sanitaria), dicha base de datos ha permitido realizar diversos estudios de investigación epidemiológica (13,21,136–140) y en servicios de salud (141–143).

Dada la experiencia del Servicio Vasco de Salud en el manejo de grandes bases de datos y en la utilización de modelos de evaluación de riesgos, se consideró que resultaba factible diseñar un nuevo instrumento para la estratificación prospectiva de toda la población. Se trata de plantear un sistema de base poblacional, basado en criterios clínicos, y sencillo de comprender y de aplicar por los profesionales sanitarios. A lo largo de este documento nos referiremos a él como FINGER (Formación e Identificación de Nuevos Grupos de Estratificación de Riesgo).

2. HIPOTESIS y OBJETIVOS:

2.1 HIPOTESIS

1.- Actualmente, las enfermedades crónicas y situaciones de multimorbilidad son muy comunes entre los habitantes del País Vasco. La prevalencia de estos problemas aumenta con la edad y privación socioeconómica. Los pacientes que presentan estas patologías tienen más necesidad de atención sanitaria, lo que incrementa el coste de su asistencia.

2.- Los sistemas de *case-mix*, diseñados en Estados Unidos como herramientas de ajuste de riesgos, son instrumentos robustos, que pueden ser empleados en un sistema nacional de salud como el nuestro para predecir el consumo de recursos sanitarios e identificar prospectivamente a los individuos con mayor necesidad de asistencia.

3.- Aunque la implantación de programas de estratificación poblacional es un componente necesario para la transformación de los sistemas sanitarios, habitualmente se emplean sistemas de *case-mix* muy elaborados, difíciles de comprender e interpretar por los clínicos. Todo ello redundaría negativamente en su aceptación por los profesionales sanitarios y disminuye su aplicabilidad.

4.- Empleando las bases de datos administrativas desarrolladas en el País Vasco hasta ahora, resulta factible desarrollar un nuevo instrumento de estratificación poblacional, basado en variables

demográficas, morbilidad atendida y contactos previos con el sistema sanitario. Para que resulte aceptable para los clínicos, se dará prioridad a la sencillez y transparencia en el diseño y a la facilidad de interpretación. A pesar de ello, este nuevo sistema contará con una capacidad suficiente desde el punto de vista estadístico para predecir el consumo de recursos sanitarios e identificar a las personas con mayor riesgo de coste elevado de su atención sanitaria, hospitalización no programada o defunción.

2.2 OBJETIVOS

El presente trabajo se ha organizado para responder a 4 objetivos diferentes:

1.- Mostrar la prevalencia de cronicidad y multimorbilidad en el País Vasco y describir el nivel de gasto sanitario a nivel individual en función de la presencia de pluripatologías y privación socioeconómica.

2.- Determinar la validez y aplicabilidad en nuestro medio de los sistemas diseñados en Estados Unidos para el ajuste de riesgo a nivel poblacional: verificar la validez de *Adjusted Clinical Groups (ACG-PM)*, *Diagnostic Cost Groups/Hierarchical Condition Categories (DCG-HCC)* y *Clinical Risk Groups (CRG)* para predecir el coste de la atención sanitaria e identificar, de manera prospectiva, a los pacientes que requerirán un consumo muy elevado de recursos en el año siguiente a su clasificación.

3.- Identificar los elementos que, actuando como barreras o facilitadores, ejercen un papel relevante en el proceso de implementación de nuevos programas de estratificación poblacional en el trabajo diario en atención primaria de salud en el País Vasco.

4.- Establecer la validez de un nuevo sistema de clasificación de pacientes y su aplicabilidad como instrumento de estratificación poblacional:

- 4.1: Analizar la validez de los modelos predictivos basados en un sistema de clasificación diseñado en el País Vasco (FINGER) para predecir el coste sanitario en los 12 meses siguientes a la clasificación de los pacientes .

- 4.2: Establecer la capacidad del citado sistema para identificar prospectivamente a las personas que presentan un mayor riesgo de hospitalización, consumo elevado de recursos sanitarios y fallecimiento.
- 4.3 Confrontar estos resultados con los obtenidos mediante la aplicación de otros sistemas de case mix en estudios previos realizados en el País Vasco.
- 4.4: Determinar la validez de estos modelos citados en subgrupos específicos de la población, como son los pacientes crónicos afectados de determinadas enfermedades específicas o los pacientes ancianos.

3. DESARROLLO DE LOS OBJETIVOS DEL ESTUDIO

3.1 OBJETIVO 1: DESCRIBIR LA PREVALENCIA Y COSTES DE LA MULTIMORBILIDAD EN EL PAÍS

VASCO

Publicado como:

Orueta JF, García-Álvarez A, García-Goñi M, Paolucci F, Nuño-Solinís R. Prevalence and costs of multimorbidity by deprivation levels in the basque country: a population based study using health administrative databases. PloS One. 2014;9(2):e89787. (144)

Prevalence and Costs of Multimorbidity by Deprivation Levels in the Basque Country: A Population Based Study Using Health Administrative Databases

Juan F. Orueta^{1*}, Arturo García-Álvarez², Manuel García-Goñi³, Francesco Paolucci^{4,5}, Roberto Nuño-Solinís²

1 Centro de Salud de Astrabudua, Osakidetza - Basque Health Service, Erandio, Bizkaia, Spain, **2** O+Berri, Basque Institute for Healthcare Innovation, Sondika, Bizkaia, Spain, **3** Departamento de Economía Aplicada II, Universidad Complutense de Madrid, Madrid, Spain, **4** The Australian National University, Acton, Australia, **5** University of Northumbria, Newcastle upon Tyne, United Kingdom

Abstract

Background: Multimorbidity is a major challenge for healthcare systems. However, currently, its magnitude and impact in healthcare expenditures is still mostly unknown.

Objective: To present an overview of the prevalence and costs of multimorbidity by socioeconomic levels in the whole Basque population.

Methods: We develop a cross-sectional analysis that includes all the inhabitants of the Basque Country (N = 2,262,698). We utilize data from primary health care electronic medical records, hospital admissions, and outpatient care databases, corresponding to a 4 year period. Multimorbidity was defined as the presence of two or more chronic diseases out of a list of 52 of the most important and common chronic conditions given in the literature. We also use socioeconomic and demographic variables such as age, sex, individual healthcare cost, and deprivation level. Predicted adjusted costs were obtained by log-gamma regression models.

Results: Multimorbidity of chronic diseases was found among 23.61% of the total Basque population and among 66.13% of those older than 65 years. Multimorbid patients account for 63.55% of total healthcare expenditures. Prevalence of multimorbidity is higher in the most deprived areas for all age and sex groups. The annual cost of healthcare per patient generated for any chronic disease depends on the number of coexisting comorbidities, and varies from 637 € for the first pathology in average to 1,657 € for the ninth one.

Conclusion: Multimorbidity is very common for the Basque population and its prevalence rises in age, and unfavourable socioeconomic environment. The costs of care for chronic patients with several conditions cannot be described as the sum of their individual pathologies in average. They usually increase dramatically according to the number of comorbidities. Given the ageing population, multimorbidity and its consequences should be taken into account in healthcare policy, the organization of care and medical research.

Citation: Orueta JF, García-Álvarez A, García-Goñi M, Paolucci F, Nuño-Solinís R (2014) Prevalence and Costs of Multimorbidity by Deprivation Levels in the Basque Country: A Population Based Study Using Health Administrative Databases. PLoS ONE 9(2): e89787. doi:10.1371/journal.pone.0089787

Editor: C. Mary Schooling, CUNY, United States of America

Received: August 7, 2013; **Accepted:** January 27, 2014; **Published:** February 27, 2014

Copyright: © 2014 Orueta et al. This is an open-access article distributed under the terms of the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

Funding: The authors have no support or funding to report.

Competing Interests: The authors have declared that no competing interests exist.

* E-mail: jon.orueta@osakidetza.net

Introduction

Most OECD countries face major challenges in (re-)organising the funding and provision of care to respond to the increasing demands of patients with chronic diseases. Notably, most of those patients suffer more than one chronic condition at the same time and become multimorbid patients [1]. In fact, it has been suggested that multimorbidity itself is the “most prevalent chronic condition” [2],[3]. Individuals manifesting multimorbidities typically have a lower quality of life, and higher degree of disability, psychological distress, risk of mortality, and utilisation of health (and social) services than if we considered their chronic conditions in isolation or individuals with a single chronic condition [4].

Therefore, it is widely accepted that health systems need to focus their strategies for confronting such problem.

Although most studies on this topic refer to the re-organisation of provision [5], [6], the economic impact is a major concern given the concentration of health expenditures on these patients [7]. This health policy challenge is particularly important in countries where there is a significant proportion of public funding, and even more so in regions affected by the current poor economic situation and outlook, including Spain. In these countries, public policy makers find themselves involved in an urgent search for efficiency in provision while still guaranteeing quality with equity in access, in many systems in the context of universal coverage.

The relationship between individual healthcare expenditures and demographic characteristics and/or morbidity has been extensively explored [8]. Nevertheless, the real impact that individuals with multimorbidity have (and will have in the near future) on healthcare costs and on the organization and management of healthcare provision and financing is yet to be seen and only recently a few authors have addressed this topic from an empirical perspective [9]. Among those who have, some have found a nearly linear relationship between increases in the number of chronic conditions and individual's healthcare costs [10], [11], while others provide evidence of an exponential rise in costs for patients with multimorbidity [12]. In this paper, we aim to contribute to this niche in the literature [4], [13].

We exploit a unique database from the Basque Country, a region in Spain, to look together at multimorbidity, healthcare expenditures, and socioeconomic characteristics. In this way, we present an analysis of the state of the art in the Basque Country with respect to its health provision and planning, describe health expenditures, and identify the real role and importance of multimorbidity in the concentration of healthcare costs. Given the similarities between the Basque population and the society and demographics of most economically developed countries, our insights into what we have learned in the Basque Country may be extrapolated to other populations.

The objectives of this study are, first, to describe the map of prevalence of chronic conditions and multimorbidity in the Basque population; second, to observe that prevalence in socioeconomic groups defined by a deprivation index [DI]; third, to present the level of health expenditures on different types of healthcare provision by individuals controlling for the presence of multimorbidity and deprivation.

Methods

This study utilized the database prepared by the population stratification programme (PREST) of the Basque Country. Such database is property of the Basque Health Service and the access to it is restricted. The study population included every individual covered on 31 August 2011 by the public health insurance in the Basque Country and who had been covered for at least 6 months in the previous year, regardless of whether they had made any contact with or use of the Basque Health Service or not. That is, practically all the inhabitants of the Basque Country are included. Diagnoses on hospital discharge forms, emergency department databases and primary care medical records are coded according to ICD-9-CM [14], while the ATC [15] coding system is used for drugs prescribed by primary care doctors. With this information, residents in the Basque Country are classified annually using ACGs [16]. Demographic variables including age on the final day of the study period, and gender, were collected, along with the area-based DI, chronic diseases recorded and yearly health costs.

The total population considered in the study is 2,262,707, of which 50.90% are female. As for the age distribution, 15% of patients are children (age <18) and 20% are over 65.

Ethical Statement

The Clinical Research Ethics Committee of the Basque Country approved this study according to the Spanish Law 14/2007 on Biomedical Research, the Ethical Principles for Medical Research of the Declaration of Helsinki and other applicable ethical principles. We used databases that employ an opaque identifier to ensure patient confidentiality. Written consent by the patients was specifically waived by the approving Committee.

Setting

The Basque Country is one of the Spanish autonomous regions with longest experience (since 1983) in managing competences in health planning and provision and a pioneer in the transition towards a chronic care model in Spain [17], [18]. In 2010 the Department of Health and Consumer Affairs of the Autonomous Region of the Basque Country launched its "Strategy for tackling the challenge of chronicity in the Basque Country" [19]. This strategy outlines the key guiding principles to improve the responsiveness of the Basque healthcare system to chronic patients' demands and thereby to enhance its efficiency and long-term financial sustainability, as well as the quality of care for chronic patients.

An important component of the strategy is to develop a tool for the risk stratification of the entire population of the Basque Country. For this purpose, a large dataset was assembled combining information on individuals from several sources (namely, primary and specialized health care records, and census data) and including clinical - and utilisation data (e.g., diagnoses, prescriptions, categorization of people according to their disease burden by means of the Adjusted Clinical Groups case-mix system [ACG] [16], [20], healthcare costs and an area-based DI).

The Basque Health System (Osakidetza) is an organization publicly funded through general taxes. It provides universal coverage to the citizens in the Basque Country. At the point of delivery, provision of care is free of charge, with the exception of pharmaceuticals, which can entail a co-payment. The percentage charged varies according to the type of illness, the level of income of the patient and his/her age.

Chronic Conditions and the Compilation of Data

Our study draws on various sources of information, and this helps to overcome some of the shortcomings of using any of them separately. In organizations such ours, where every resident is registered on the list of a GP who acts as a gatekeeper for other levels of care, primary care records are considered a reliable guide to the prevalence of chronic illnesses. However, the extent to which the records of diagnoses are complete is influenced by a range of factors [21],[22],[23] and their combined use with inpatient and outpatient specialised care can produce more accurate estimates [24]. On the other hand, prescriptions records can provide adequate information to identify patients with some conditions [25], [26]. However, an exhaustive process of data capture may lead to overestimation, detecting illnesses that are long-lasting, but not currently active. In a recent study, Barnett et al. (2012) developed a mixed method to identify 40 chronic diseases [27], establishing specific criteria for each; depending on the characteristics of the pathology, in some cases an isolated diagnosis is accepted, in others prescriptions, diagnosis plus prescriptions in the last year or a given number of prescriptions are required.

In the present study, we considered four years of data for each of the individuals in the Basque Country. Taking advantage of and adapting the aforementioned methodology [27], we developed a list of 52 health conditions and defined a specific criterion for each to consider it active. A description of this process is included as supporting material (File S1). For the purposes of the study, multimorbidity was defined as the coexistence of two or more of these conditions in the same patient.

Healthcare Costs

For the period between 1 September 2010 and 31 August 2011, we estimated healthcare costs of primary care prescriptions recorded in electronic health records based on the market value

Table 1. Averages of chronic diseases and percentage of patients with comorbidity in patient groups according to sex, age and deprivation index.

	Average number of chronic illnesses per patient										Number and percentage (%) of patients with multimorbidity (2+ chronic diseases)				
	General average	Deprivation index					Deprivation index					All			
		1	2	3	4	5	1	2	3	4	5				
ALL	0.97	0.84	0.92	0.98	1.06	1.08	98,356 (20.52%)	108,992 (22.37%)	109,076 (23.83%)	109,425 (25.89%)	108,408 (26.07%)	534,257 (23.61%)			
Sex															
Men	0.88	0.77	0.85	0.90	0.97	0.95	42,684 (18.66%)	48,688 (20.38%)	48,501 (21.43%)	48,794 (23.24%)	46,950 (22.68%)	235,617 (21.21%)			
Women	1.06	0.90	0.99	1.07	1.16	1.21	55,672 (22.22%)	60,304 (24.30%)	60,575 (26.19%)	60,631 (28.50%)	61,458 (29.43%)	298,640 (25.93%)			
Age group															
00–04	0.11	0.10	0.10	0.11	0.13	0.15	144 (0.70%)	179 (0.81%)	189 (0.89%)	146 (1.17%)	275 (1.41%)	933 (0.97%)			
05–11	0.17	0.13	0.16	0.17	0.18	0.21	352 (1.18%)	491 (1.54%)	513 (1.73%)	442 (1.88%)	577 (2.39%)	2,375 (1.71%)			
12–17	0.17	0.13	0.16	0.17	0.18	0.20	395 (1.56%)	447 (1.90%)	400 (1.90%)	363 (2.08%)	412 (2.38%)	2,017 (1.93%)			
18–34	0.26	0.20	0.25	0.27	0.28	0.31	2,952 (3.10%)	3,857 (4.02%)	4,076 (4.57%)	4,141 (4.90%)	4,609 (5.48%)	19,635 (4.37%)			
35–44	0.44	0.35	0.41	0.45	0.46	0.51	5,032 (6.99%)	7,185 (8.70%)	7,633 (9.50%)	7,459 (9.91%)	8,675 (11.14%)	35,984 (9.27%)			
45–54	0.76	0.64	0.74	0.78	0.80	0.89	12,093 (15.68%)	14,171 (18.33%)	13,932 (19.67%)	13,217 (20.27%)	14,143 (22.90%)	67,556 (19.18%)			
55–64	1.40	1.17	1.35	1.44	1.50	1.60	20,737 (31.89%)	22,424 (36.50%)	22,374 (39.38%)	21,182 (40.60%)	19,678 (43.34%)	106,395 (37.88%)			
65–69	2.00	1.74	1.95	2.07	2.07	2.21	12,363 (47.63%)	13,030 (53.38%)	13,364 (56.03%)	13,547 (56.26%)	12,571 (59.07%)	64,875 (54.25%)			
70–74	2.43	2.16	2.36	2.51	2.52	2.62	10,263 (57.34%)	11,223 (62.45%)	11,566 (65.50%)	12,343 (65.88%)	12,046 (67.55%)	57,441 (63.76%)			
75–79	2.91	2.62	2.81	2.97	2.99	3.12	12,213 (65.92%)	13,679 (70.14%)	13,917 (73.14%)	15,074 (73.41%)	14,792 (75.29%)	69,675 (71.65%)			
80–84	3.26	2.97	3.22	3.34	3.31	3.46	10,950 (71.63%)	11,721 (75.99%)	11,456 (78.24%)	11,902 (77.48%)	11,644 (78.89%)	57,673 (76.41%)			
85+	3.05	2.78	3.03	3.13	3.14	3.24	10,862 (66.40%)	10,585 (71.20%)	9,656 (71.76%)	9,609 (72.06%)	8,986 (73.12%)	49,698 (70.69%)			

Note: Deprivation index is arranged in quintiles. The higher socioeconomic status is represented as 1, while the lowest one corresponds to 5.
doi:10.1371/journal.pone.0089787.t001

Table 2. Healthcare spending by number of chronic conditions.

No. of chronic diseases	% of population	% of overall spending					Total
		Primary care	Specialized outpatient care	Emergency department attendances	Prescriptions	Inpatient stays	
0	57.08	29.22	23.09	44.58	4.84	13.29	19.43
1	19.31	20.8	20.61	19.69	13.98	12.97	17.02
2	10.04	15.63	16.54	10.43	18.53	13.29	15.26
3	5.82	11.65	12.73	7.2	18.28	12.94	13.15
4	3.41	8.25	9.23	5.37	14.97	11.59	10.5
5+	4.34	14.44	17.8	12.73	29.4	35.91	24.65
Total	100	100	100	100	100	100	100
1+ conditions (i.e chronic patients)	42.92	70.78	76.91	55.42	95.16	86.71	80.57
2+ conditions (i.e., multimorbid patients)	23.61	49.98	56.3	35.73	81.18	73.74	63.55

doi:10.1371/journal.pone.0089787.t002

of the drugs. For other variables (e.g., visits to Accident & Emergency [A&E], rehabilitation sessions, outpatient care, primary care visits, laboratory tests and radiological examinations ordered by primary care, and various outpatient procedures such as dialysis, radiotherapy and chemotherapy), the number of services used by each patient was multiplied by standardized costs (the average cost of each service provided to a patient treated in Osakidetza, according to calculations made by the aforementioned organisation). The costs of hospitalisation and outpatient surgery were calculated in relation to their cost-weights in the corresponding diagnosis-related groups (DRGs). Some services for which it was not possible to obtain information were excluded; these include admission to psychiatric hospitals, home care and day care services (except for the procedures mentioned above), transportation, and prostheses and other equipment provided to patients at home.

Socioeconomic Information

The DI, defined by census tract, was used as a socioeconomic indicator. This index is an ordinal variable, categorized into five levels (DI quintiles), providing a measure of the socioeconomic characteristics of the population of census tracts. The DI was elaborated and published in 2008. Its design allows for the estimation of socioeconomic and environmental inequalities among inhabitants by censal code in Spain. Its calculus takes into account the percentages of residents who are manual workers, unemployed, temporary employees, or have an inadequate level of educational attainment, overall and also specifically among young people [28], given the most recent Census (2001) available.

Statistical Analysis

Tables 1–7 present the descriptive statistics of our data. In order to compare healthcare cost for individuals belonging to the different categories of the DI given their number of chronic conditions, we utilize the Kruskal-Wallis non-parametric test.

We use the Generalized Linear Model (GLM) with gamma distribution and log link [29] to evaluate the relationship between the number of chronic conditions and cost after adjusting for confounding factors. As Healthcare cost data are typically non-normally distributed with a skew towards the right, Gamma regression is a better modeling approach to deal with this skewness than Ordinary Least Square (OLS) regression [30], [31], [32]). In our model, individual total cost was our dependent variable. The independent variables we use were sex, age (by groups), DI, and the number of chronic conditions. Given that age groups behave differently of males and females in terms of the utilization of health services and its cost, we also allowed for the interaction of age and sex. Predicted mean adjusted costs were obtained by using the recycled predictions methodology [33], [34]. This method calculates the mean adjusted cost for each category in the variable of interest as the average of all individual predictions based on the regression model when all subjects are assigned to such category, while holding constant all other model covariates.

Given that our goal is to observe the relationship between the increase in individual cost and the number of chronic conditions, we chose, by consensus within the research team, 10 among the most common pathologies and whose cost is more significant. At the same time, our methodology allows us to show how the increase in individual cost is related to the characteristics of specific pathologies. Hence, we run a log-gamma model separately for each pathology using as independent variables age, sex, DI, the number of other pathologies suffered by the patient, and the interaction of each pathology with the number of other pathologies. Out of those estimation models, we obtain the mean

Table 3. Comparison of medians of annual primary care costs per patient, depending on number of chronic diseases and deprivation index.

PRIMARY CARE COST: median (percentile 25th–75th)											
No, Chronic conditions	Deprivation Index										All
	1	2	3	4	5	6	7	8	9	10	
0	37 € (0–150)	74 € (0–189)	74 € (0–204)	74 € (0–202)	74 € (0–215)	74 € (0–189)					*
1–3	267 € (137–447)	296 € (150–479)	302 € (152–491)	316 € (165–506)	317 € (167–509)	300 € (150–486)					*
4–6	562 € (360–845)	606 € (401–892)	623 € (412–903)	630 € (418–911)	623 € (417–899)	611 € (402–892)					*
7–9	861 € (558–1264)	898 € (589–1318)	946 € (634–1361)	924 € (621–1301)	923 € (632–1290)	912 € (610–1304)					*
10+	1,225 € (861–1803)	1,303 € (883–1817)	1,252 € (832–1818)	1,268 € (913–1758)	1,283 € (885–1774)	1,264 € (872–1790)					#
All	113 € (0–313)	152 € (37–365)	176 € (37–387)	185 € (37–406)	189 € (37–417)	163 € (37–376)					*

*p<0.001;

#non-significant.

doi:10.1371/journal.pone.0089787.t003

adjusted cost (by recycled predictions methods) and analyze whether they vary when the number of comorbidities increases.

All this analysis was performed using SAS (version 9.2).

Results

Prevalence of Multimorbidity

Table 1 shows the distribution of the population by age group as well as the average number of chronic diseases per patient, this being 0.97 overall. The percentage of the population with multimorbidity is 23.61%, representing 55% of patients with any chronic condition, given that 42.92% have at least one chronic condition (as shown in Table 2).

Chronic conditions are more common in females than in males, and their prevalence rises with age up to 85 years old, when there is a slight decrease. Multimorbidity affects more than half of the population over 65 and more than three quarters of those between 80 and 84 years old.

Multimorbidity and Socioeconomic Status

Those with a greater number of illnesses tended to live in more deprived areas. This pattern is seen in both sexes and all age groups. When comparing the most and least deprived groups, the

differences are larger, in relative terms, at younger ages and somewhat less so in the older groups (Table 1).

Concentration of Health Expenditures in Multimorbid Patients

Table 2 shows the percentage of healthcare spending by number of chronic diseases. Chronic patients (42.92% of the population) are responsible for 80.57% of total healthcare expenditures (86.71% for inpatient care and 95.16% for prescriptions). Importantly, even in the case of A&E, spending on chronic patients represents more than half of the total (55.42%). The concentration of health expenditures is evidenced by the fact that 23.61% of patients have multiple conditions (multimorbidity according to the definition used for this study) but they account for 63.55% of total healthcare expenditures. Of those, patients with five or more chronic conditions, representing less than 5% of the population (4.33%), consume almost a quarter of the total healthcare resources (24.65%).

Health Expenditures and Socioeconomic Status

The average cost of the healthcare provided for each patient was €1,124. Tables 3–7 show the median, 25th and 75th percentile of costs as a function of number of chronic conditions and DI.

Table 4. Comparison of medians of annual specialised care costs per patient, depending on number of chronic diseases and deprivation index.

SPECIALISED CARE COST without hospitalization, but including A&E: median (percentile 25th–75th)											
No, Chronic conditions	Deprivation Index										All
	1	2	3	4	5	6	7	8	9	10	
0	0 € (0–153)	0 € (0–164)	0 € (0–164)	0 € (0–164)	0 € (0–164)	0 € (0–164)					*
1–3	164 € (0–410)	164 € (0–484)	164 € (0–492)	164 € (0–492)	246 € (0–563)	164 € (0–492)					*
4–6	410 € (153–891)	481 € (164–973)	492 € (164–1019)	552 € (235–1044)	563 € (246–1055)	492 € (164–984)					*
7–9	727 € (317–1372)	820 € (399–1493)	820 € (410–1535)	891 € (410–1596)	891 € (481–1607)	820 € (410–1535)					*
10+	1,214 € (634–2235)	1,225 € (645–2077)	1,279 € (705–2018)	1,307 € (727–2144)	1,285 € (705–2160)	1,278 € (694–2122)					#
All	0 € (0–246)	82 € (0–328)	82 € (0–328)	82 € (0–399)	153 € (0–410)	82 € (0–328)					*

*p<0.001;

#non-significant.

doi:10.1371/journal.pone.0089787.t004

Table 5. Comparison of medians of prescriptions costs per patient, depending on number of chronic diseases and deprivation index.

PRESCRIPTIONS: median (percentile 25th–75th)												
No, Chronic conditions	Deprivation Index										All	
	1	2	3	4	5	6	7	8	9	10		
0	0 € (0–4)	0 € (0–8)	0 € (0–9)	0 € (0–10)	0 € (0–10)	0 € (0–10)	0 € (0–10)	0 € (0–10)	0 € (0–10)	0 € (0–10)	0 € (0–8)	*
1–3	70 € (6–319)	66 € (8–295)	65 € (8–292)	70 € (10–305)	65 € (9–293)	67 € (8–301)						*
4–6	626 € (269–1183)	643 € (283–1217)	645 € (285–1209)	650 € (287–1240)	646 € (277–1231)	642 € (281–1217)						*
7–9	1,118 € (579–1863)	1,184 € (611–1959)	1,202 € (640–1985)	1,204 € (654–1993)	1,186 € (612–1978)	1,180 € (623–1959)						*
10+	1,509 € (778–2446)	1,639 € (923–2528)	1,686 € (933–2599)	1,627 € (970–2588)	1,612 € (944–2552)	1,612 € (921–2557)						**
All	2 € (0–61)	6 € (0–77)	8 € (0–88)	10 € (0–110)	10 € (0–106)	7 € (0–87)						*

*p<0.001;

**p<0.05.

doi:10.1371/journal.pone.0089787.t005

According to these indicators, the total healthcare cost per person is slightly higher in more deprived social areas. The same trend is seen comparing the figures of the groups of patients with different numbers of chronic diseases. Those differences are statistically significant ($p<0.001$) for all different categories of health expenditure, both for the general population and for each specific group of multimorbid patients, but for those individuals with 10 or more pathologies, where only the difference in expenditures in pharmaceutical prescriptions is statistically significant ($p<0.05$).

Regression Analysis: Relationships between Health Expenditures and Number of Chronic Diseases

We present the results from the Generalized Linear Model (GLM) with gamma distribution in the supporting material (table B in File S2). From those estimations we have obtained the average individual cost adjusted by the independent variables age, sex DI and number of pathologies, as shown in tables 8 and 9.

Once adjusted per number of chronic conditions and socioeconomic characteristics, the effect of ageing is small. Furthermore, individual cost for children (with an equal number of diseases) is greater than for other ranges of age. With respect to age, individual cost for females is lower than for males for all ages but in the range of 18–44 years old, as expected due to obstetric care.

We also analyze the effect of socioeconomic status through the DI. The average individual cost for those in the most deprived socioeconomic group is significantly (25%) higher than that of individuals in the most favorable socioeconomic group.

The increase in healthcare expenditures observed in the number of chronic diseases is shown in Table 9. The annual average cost for patients with one chronic disease is €637 higher than that for people with none, while the effect of “adding” a second, third or fourth disease becomes progressively more expensive and, for example, the cost of another illness after the eighth rises to an additional € 1,657 per year.

Health Expenditures for Patients with Specific Conditions

In our analysis, we find that it is not only the number of chronic diseases what matters when looking at the increase in cost, but also which are the conditions suffered by patients and specifically,

which is the considered primary condition. Table 10 and figure 1 present average costs by coexistence of other conditions for some specific health conditions. On the one hand, for chronic obstructive pulmonary disease (COPD), diabetes mellitus, ischaemic heart disease and heart failure there are progressive increases according to the number of other coexisting conditions (there being a two- to three-fold difference between the annual cost of patients with and without any of these four conditions, in the case of patients with another eight conditions). On the other hand, the reverse is true in the cases of depression or anxiety, greater comorbidity leading to progressively smaller rises and even negative differences for comorbidity of seven or more chronic diseases, and malignancies or cerebrovascular disease, with costs rising up to a point (other six diseases) and falling afterwards.

Discussion

In this paper, we utilize a unique database on the entire population of the Basque Country. The Basque Country being a region in Spain, its size in terms of population, more than two million people, is similar to that from small countries in Europe like Lithuania, Slovenia or Latvia, and only half of the population than countries as Norway, Ireland or Croatia, being greater than almost half of the States in the US. The uniqueness of our data set -with respect to related articles in the literature-, consists in it containing four years of individual -clinical and cost- data from different sources of information to cover a great proportion of the public resources used, for the entire population of the Basque Country, as well as an indicator of socioeconomic status. Hence, we avoid the potential biases of taking into account only a proportion of the population (such as the elderly), one type of healthcare service provision (such as primary care), or using information only from some selected health centres.

We show evidence of how multimorbidity is a common phenomenon and its presence increases with the age of the population considered, and of the concentration of healthcare expenditures in patients with multimorbidity). Together with the process of ageing in the population, common to all developed countries, our results add to the body of evidence justifying the great international concern about public health provision,

Table 6. Comparison of medians of hospitalizations costs per patient, depending on number of chronic diseases and deprivation index.

HOSPITALIZATIONS: percentage of citizens with no admissions(%); median (percentile 25th–75th) of costs of patients with any		Deprivation Index					All
No. Chronic conditions		1	2	3	4	5	
0	97% 2,075 € (1602–3034)	97% 1,979 € (1602–2732)	97% 1,979 € (1602–2734)	97% 1,979 € (1602–2831)	96% 1,979 € (1602–2734)	97% 1,979 € (1602–2858)	*
1–3	92% 3,046 € (2164–5629)	91% 2,800 € (2148–5092)	91% 2,841 € (2129–4963)	91% 2,800 € (2156–5106)	91% 2,734 € (2071–4929)	91% 2,853 € (2148–5152)	*
4–6	78% 4,692 € (2532–9126)	76% 4,593 € (2475–9042)	76% 4,632 € (2502–9037)	75% 4,517 € (2476–8949)	74% 4,420 € (2436–8608)	76% 4,563 € (2497–8977)	*
7–9	56% 5,944 € (3425–11230)	53% 6,514 € (3420–12417)	53% 6,442 € (3420–12455)	52% 6,499 € (3420–12620)	52% 6,202 € (3420–11744)	53% 6,335 € (3420–12132)	*
10+	30% 10,300 € (4692–18340)	30% 8,747 € (4556–16519)	29% 8,771 € (4409–16609)	30% 8,839 € (4385–15240)	32% 9,908 € (4563–16814)	30% 9,378 € (4495–16593)	#
All	94% 3,014 € (1996–5806)	93% 2,797 € (1979–5693)	93% 2,897 € (1979–5763)	92% 3,009 € (2037–5864)	92% 2,936 € (1992–5806)	93% 2,936 € (1992–5806)	*

* $p < 0.0001$;

non-significant.

doi:10.1371/journal.pone.0089787.t006

planning, and funding for patients with multimorbidity in the near future. Furthermore, there are two respects in which the Basque Country is ahead of other regions and countries in the need for efficiency in health provision, making these findings particularly relevant for the international audience. First, the population in the Basque Country is already slightly more aged than that of Spain as a whole [35], one of the most aged developed countries. Second, the current economic conditions in Spain produces a sense of urgency among policy makers and is resulting in numerous implementations of policies promoting direct and indirect cuts in health expenditures [36].

An innovative pillar of our analysis is to include a socioeconomic indicator and explore its relationship with the prevalence and healthcare expenditures of patients with multimorbidity. We show evidence that both the prevalence of multimorbidity and thus the level of need in provision, are greater in more deprived geographical areas. In the Basque Country, there is no evidence of inequity (or discrimination against populations in more deprived areas) as the greater the need, the greater the level of public health expenditures. This reflects decades of planning and development of primary care services in the National Health Service. However, the greater prevalence of multimorbid patients in more deprived areas is of public concern in itself and should be taken into account as a gradient between health and wealth.

We also find evidence of how, on average, the annual use of healthcare resources by chronically ill patients grows as the number of chronic diseases increases. Notably, our data suggests that this increase is not linear but rather tends to be progressive. This is the most common pattern and, it would seem, the most expected for the prevalence of all chronic conditions. There are exceptions, however, namely depression and anxiety: patients with either of these conditions and more than five (in the case of depression) or two (in the case of anxiety) other chronic diseases, use a lower level of resources than if they only had these other chronic health problems. In other conditions, such as malignant neoplasms or cerebrovascular disease, healthcare costs increase progressively with multimorbidity, the magnitude of the increase growing for up to six more diseases but falling thereafter. That result, although initially paradoxical, might be explained through different interpretations. Patients with some of those chronic conditions (as mental condition) might be reluctant to look for or might find more obstacles to access health service provision than individuals without those conditions. Also, clinical records for patients with multiple diseases and the elderly can be particularly difficult [37] and therefore, their diagnoses are less accurate. Hence, physicians may not record a diagnosis of anxiety or depression when there seems to be a clear reason for it. At the same time, it is also plausible that in the case of some especially severe conditions, as malignancies, treatments tend to be more aggressive for patients with less comorbidities than in those, more complex patients, with a greater combination of chronic problems. Lastly, although we do account for the number of chronic diseases and which conditions are those, we have no information on their level of severity, and for each specific case, some might be more severe than others.

We have shown how in the Basque Country health expenditures are concentrated in patients with multimorbidity, and within this group, the most expensive are those with heart failure, ischaemic heart disease, and diabetes mellitus among other conditions. Having identified the most expensive populations in terms of public health expenditures, the next step is to design strategies and undertake proactive interventions specifically for those patients. The aforementioned “Strategy for tackling the challenge of chronicity in the Basque Country” [19], launched in 2010,

Table 7. Comparison of medians of total health care costs per patient, depending on number of chronic diseases and deprivation index.

TOTAL COST: median (percentile 25th–75th)											
No, Chronic conditions	Deprivation Index										
	1	2	3	4	5	All					
0	82 € (0–324)	147 € (0–405)	153 € (0–426)	153 € (0–424)	162 € (0–465)	139 € (0–404)					*
1–3	682 € (320–1312)	724 € (345–1397)	743 € (356–1443)	780 € (377–1498)	799 € (384–1543)	744 € (355–1437)					*
4–6	2,108 € (1242–4100)	2,278 € (1348–4433)	2,302 € (1376–4545)	2,391 € (1433–4709)	2,414 € (1433–4753)	2,303 € (1369–4535)					*
7–9	4,461 € (2440–9341)	5,097 € (2720–10450)	5,143 € (2819–10549)	5,207 € (2832–10701)	5,172 € (2820–10450)	5,048 € (2734–10349)					*
10+	10,275 € (5210–20071)	10,280 € (4960–19189)	10,331 € (5341–18544)	10,178 € (5270–18380)	9,956 € (5011–18653)	10,212 € (5130–18767)					#
All	261 € (26–798)	342 € (68–939)	373 € (77–1011)	402 € (82–1096)	431 € (93–1149)	356 € (65–988)					*

* $p < 0.001$;

non-significant.

doi:10.1371/journal.pone.0089787.t007

already encouraged changes in this direction. Our most recent results, however, underline the need to keep making further efforts in the re-organisation of health provision specifically for the patients identified, who are those that will benefit the most from increasing care coordination. In this area, integrated care approaches for patients with multiple conditions are increasingly popular in Spain and preliminary evaluations seem promising in terms of their effectiveness [38].

The goal is to improve the level of control of the relevant indicators for patients identified as being most in-need or at-risk, e.g., those that are most expensive, are readmitted most frequently or fulfil various clinical criteria [39], [40].

Our study has certain limitations. Firstly, administrative databases obviously only contain information about health problems for which people seek medical care. Therefore, the prevalence of diseases only reflects attended morbidity excluding

conditions that might be present but have not yet manifested or have not been detected by either the patients or their doctors. This is quite common in chronic diseases and it is influenced by various factors, such as accessibility to healthcare services, though this is not questioned in our setting for the case of the Basque Health Service. Secondly, our database does not contain information on psychiatric hospitals; and, even though patients admitted in such hospitals are also usually cared for by primary care doctors, given their special characteristics, it is possible that their health records were not as complete as for the rest of the population. Thirdly, employing socioeconomic indicators at the level of area of residence, our study has the limitations common to ecological studies. Finally, cost data are restricted to expenditures funded by

Table 8. Healthcare expenditure.

Age Group	Male	Female
00–04	2,550	2,316
05–11	1,125	1,057
12–17	933	859
18–34	798	1,298
35–44	818	1,300
45–54	921	1,033
55–64	1,098	1,083
65–69	1,231	1,156
70–74	1,262	1,187
75–79	1,303	1,209
80–84	1,254	1,161
85+	1,078	1,030

Means, adjusted by generalized linear regression model, of several groups of population.

doi:10.1371/journal.pone.0089787.t008

Table 9. Healthcare expenditure.

Deprivation Index	
1	976
2	1,117
5	1,155
4	1,186
5	1,226
Number of Chronic Diseases	
0	380
1	1,017
2	1,735
3	2,533
4	3,406
5	4,506
6	5,799
7	7,348
8	8,759
9	10,417
10+	13,891

Means, adjusted by generalized linear regression model, of several groups of population.

doi:10.1371/journal.pone.0089787.t009




Figure 1. Difference in average of adjusted annual cost (in euros) per patient, by number of coexisting chronic diseases according to the presence of certain selected diseases.

doi:10.1371/journal.pone.0089787.g001

the public sector, and individual health care costs were calculated from the standard pricing of the services provided, with the exception of drug costs (based on their market value) and DRGs (average costs from cost accounting). That is, certain costs have not been considered, namely the costs of activities not included in the dataset, e.g., admissions to mental health hospitals, home hospitalisation, etc. (we estimate that 21.58% of the total cost is not included in our analysis). We interpret the lack of data on use and costs in private health centres as a plausible explanation for the greater need (and higher demand) for outpatient services from more deprived socioeconomic areas. However, even if that were to be true, the fact that hospitalisation is similar for all socioeconomic groups demonstrates the trust of the entire population in the public provision under the national health service for expensive treatments and maybe some adverse selection in the private health insurance market. Further, this paper is focused on the organisation of public health service provision and planning, and thus, private health provision is beyond the scope of our analysis. At the same time, the fact that some health expenditures are derived from cost standardisation might explain the lower concentration of health expenditures in the most expensive patients compared to other studies in the literature, given that the level of prices (unit cost) is in Spain lower than in that in other countries.

In essence, multimorbidity occurs as a complex phenomenon and patients with multiple health problems do not share a common set of characteristics. It is known that the relationship

between comorbidity, quality and healthcare outcomes is not uniform, and depends upon the specific combination of diseases [3]. Future studies are needed to determine whether the observed higher expenditures among multimorbid patients are justified or not, in order to detect possible inefficiencies in their care. Besides, further research is required to characterize the diverse subgroups of patients with multimorbidity, to implement specific, patient-centred care programmes.

Conclusions

Multimorbidity is a very common finding, its prevalence rises with age, and it is related to unfavourable socioeconomic factors. The costs of caring for chronic patients tend to increase dramatically with the number and combination of comorbidities, although the pattern varies for certain specific diseases. Our paper using comprehensive data on the utilization of all levels of public health services by the entire population of the Basque Country shows the burden of multimorbidity in a population engaged in an irreversible process of population ageing and the implications of multimorbidity for patients. Moreover, the current economic crisis has pushed the Basque Country, in search of efficiency, to innovate in the study of multimorbidity and its effect in patients, families and caregivers. This is perhaps the most important current challenge for policy makers, administrators, clinicians, and researchers in our health system, and probably also in that of

Table 10. Difference in average of adjusted annual cost (in euros) per patient, by number of coexisting chronic diseases according to the presence of certain selected diseases.

N Chronic Conditions	Anxiety			Atrial Fibrillation			Cerebrovascular disease			COPD			Depression				
	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference		
0	375	742	366	379	1,504	1,125	379	1,395	1,015	379	1,357	978	379	1,254	875		
1	1,098	1,344	246	1,015	1,915	900	1,014	2,080	1,066	1,012	2,191	1,179	1,013	1,694	680		
2	1,906	2,102	196	1,732	2,749	1,017	1,727	2,948	1,221	1,720	3,031	1,311	1,739	2,324	585		
3	2,777	2,850	72	2,522	3,652	1,129	2,510	3,770	1,260	2,502	4,014	1,512	2,566	3,087	521		
4	3,780	3,841	61	3,381	4,741	1,361	3,369	4,751	1,381	3,343	5,236	1,893	3,482	3,914	432		
5	5,052	5,000	-52	4,467	6,091	1,624	4,472	5,898	1,426	4,397	6,621	2,224	4,701	4,993	292		
6	6,544	6,135	-409	5,718	7,526	1,808	5,788	7,484	1,696	5,623	8,422	2,799	6,131	6,051	-80		
7	8,473	7,417	-1,056	7,293	9,052	1,759	7,324	8,385	1,061	7,023	9,422	2,399	7,962	7,183	-779		
8	10,167	9,012	-1,154	8,599	10,643	2,045	8,943	9,646	704	8,523	11,598	3,075	9,658	8,717	-941		
9	12,077	11,000	-1,077	10,278	12,347	2,070	10,855	11,003	149	9,765	13,399	3,635	11,484	10,231	-1,253		
Diabetes Mellitus																	
Heart failure																	
w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference	w/o such condition	+Observed condition	Difference
380	1,101	721	379	2,123	1,744	383	868	485	379	1,296	916	379	2,964	2,585	379	2,964	2,585
1,014	1,532	518	1,016	3,108	2,091	1,055	1,573	518	1,016	2,236	1,220	961	3,907	2,945	961	3,907	2,945
1,763	2,289	526	1,733	4,044	2,311	1,851	2,336	484	1,720	2,934	1,214	1,593	4,403	2,811	1,593	4,403	2,811
2,596	3,192	595	2,519	5,081	2,562	2,785	3,206	421	2,505	3,911	1,406	2,333	5,077	2,744	2,333	5,077	2,744
3,484	4,288	804	3,354	6,600	3,245	3,739	4,273	534	3,348	5,025	1,676	3,153	6,064	2,911	3,153	6,064	2,911
4,607	5,551	944	4,342	7,716	3,374	4,993	5,504	512	4,424	6,238	1,814	4,209	7,654	3,445	4,209	7,654	3,445
5,936	7,278	1,342	5,518	9,326	3,808	6,635	7,035	400	5,704	7,862	2,159	5,372	9,350	3,978	5,372	9,350	3,978
7,379	9,070	1,690	6,827	10,601	3,775	8,246	8,430	184	7,201	9,610	2,409	6,834	10,069	3,235	6,834	10,069	3,235
8,439	10,348	1,909	7,947	12,317	4,370	9,540	10,033	494	8,434	11,040	2,605	8,377	11,510	3,133	8,377	11,510	3,133
10,448	12,133	1,684	9,199	14,069	4,869	11,302	11,564	262	10,140	12,738	2,598	10,073	13,000	2,927	10,073	13,000	2,927

Note: These series have been truncated, because patients with +10 chronic diseases are very scarce (<0.01% of total population); beyond such limit, the groups exhibit a great variability in their results due to their small size.
doi:10.1371/journal.pone.0089787.t010

other developed countries, to guarantee the quality of care provided.

Supporting Information

File S1 Definition of Chronic Conditions.
(DOCX)

File S2 Generalized linear model (GLM) with gamma distribution.
(DOCX)

References

1. OECD (2011) Health Reform: Meeting the Challenge of Ageing and Multiple Morbidities. Paris: Organisation for Economic Co-operation and Development. Available: <http://www.oecd-ilibrary.org/content/book/9789264122314-en>. Accessed 14 May 2013.
2. Tinetti ME, FT (2012) Designing health care for the most common chronic condition—multimorbidity. *JAMA* 307: 2493–2494. doi:10.1001/jama.2012.5265.
3. Vogeli C, Shields AE, Lee TA, Gibson TB, Marder WD, et al. (2007) Multiple chronic conditions: prevalence, health consequences, and implications for quality, care management, and costs. *J Gen Intern Med* 22 Suppl 3: 391–395. doi:10.1007/s11606-007-0322-1.
4. Boyd CM, Fortin M (2010) Future of Multimorbidity Research: How Should Understanding of Multimorbidity Inform Health System Design?. *Public Health Reviews* 32: 451–474. Available: <http://core.kmi.open.ac.uk/display/964118>. Accessed 25 April 2013.
5. Smith SM, Soubhi H, Fortin M, Hudon C, O'Dowd T (2012) Managing patients with multimorbidity: systematic review of interventions in primary care and community settings. *BMJ* 345: e5205–e5205. doi:10.1136/bmj.e5205.
6. Roland M, Paddison C (2013) Better management of patients with multimorbidity. *BMJ* 346: f2510–f2510. doi:10.1136/bmj.f2510.
7. Anderson G, Hopkins J (2011) The latest disease burden challenge: People with multiple chronic conditions, in OECD, Health Reform: Meeting the Challenge of Ageing and Multiple Morbidities. OECD Publishing, pp. 15–35. Available: <http://www.oecd-ilibrary.org/content/chapter/9789264122314-4-en>. Accessed 14 May 2013.
8. Van de Ven WPMM, Ellis RP (2000) Chapter 14 Risk adjustment in competitive health plan markets. In: Anthony J, Culyer and Joseph P Newhouse, Handbook of Health Economics. Elsevier, Vol. Volume 1, Part A, pp. 755–845. Available: <http://www.sciencedirect.com/science/article/pii/S1574006400801730>. Accessed 25 April 2013.
9. Lehnert T, König H-H (2012) [Effects of multimorbidity on health care utilization and costs]. *Bundesgesundheitsblatt Gesundheitsforschung Gesundheitschutz* 55: 685–692. doi:10.1007/s00103-012-1475-6.
10. Naessens JM, Stroebel RJ, Finnie DM, Shah ND, Wagie AE, et al. (2011) Effect of multiple chronic conditions among working-age adults. *Am J Manag Care* 17: 118–122.
11. Yu W, Ravelo A, Wagner TH, Phibbs CS, Bhandari A, et al. (2003) Prevalence and costs of chronic conditions in the VA health care system. *Med Care Res Rev* 60: 146S–167S.
12. Charlson M, Charlson RE, Briggs W, Hollenberg J (2007) Can Disease Management Target Patients Most Likely to Generate High Costs? The Impact of Comorbidity. *J Gen Intern Med* 22: 464–469. doi:10.1007/s11606-007-0130-7.
13. Starfield B, Kinder K (2011) Multimorbidity and its measurement. *Health Policy* 103: 3–8. doi:10.1016/j.healthpol.2011.09.004.
14. Spanish Institute of Health Information: (2012) Spanish version (eCIE9MC) of the Electronic International Classification of Diseases, Ninth Revision, Clinical Modification (ICD-9-CM) (8th Ed., Version 1.1.0). Available: http://eciemaps.mspis.es/ecieMaps/browser/index_9_2012.html. Accessed 14 March 2013.
15. The WHO Collaborating Centre for Drug Statistics Methodology (2012) International language for drug utilization research ATC/DDD. Available: http://www.whocc.no/atc_ddd_index/. Accessed 14 March 2013.
16. Johns Hopkins Bloomberg School of Public Health (2009) The Johns Hopkins ACG Case-Mix System Technical Reference Guide Manual Version 9.0. Baltimore, MD.
17. Nuño R, Piñera K (2010) Strategy for tackling the challenge of chronicity. *Health Policy Monitor*. Available: <http://www.hpm.org/es/a16/1.pdf>. Accessed 14 May 2013.
18. García-Goñi M, Hernández-Quevedo C, Nuño-Solinis R, Paolucci F (2012) Pathways towards chronic care-focused healthcare systems: evidence from Spain. *Health Policy* 108: 236–245. doi:10.1016/j.healthpol.2012.09.014.
19. Department of Health and Consumer Affairs of the Basque Government and Osakidetza (2010) A strategy to tackle the challenge of chronicity in the Basque country. Available: <http://cronicidad.blog.euskadi.net/descargas/plan/ChronicityBasqueCountry.pdf>. Accessed 14 March 2013.
20. Weiner JP, Dobson A, Maxwell SL, Coleman K, Starfield B, et al. (1996) Risk-adjusted Medicare capitation rates using ambulatory and inpatient diagnoses. *Health Care Financ Rev* 17: 77–99.
21. O'Malley KJ, Cook KF, Price MD, Wildes KR, Hurdle JF, et al. (2005) Measuring Diagnoses: ICD Code Accuracy. *Health Serv Res* 40: 1620–1639. doi:10.1111/j.1475-6773.2005.00444.x.
22. Majeed A (2004) Sources, uses, strengths and limitations of data collected in primary care in England. *Health Stat Q*: 5–14.
23. Gorina Y, Kramarow EA (2011) Identifying chronic conditions in Medicare claims data: evaluating the Chronic Condition Data Warehouse algorithm. *Health Serv Res* 46: 1610–1627. doi:10.1111/j.1475-6773.2011.01277.x.
24. Orueta JF, Nuño-Solinis R, Mateos M, Vergara I, Grandes G, et al. (2012) Monitoring the prevalence of chronic conditions: which data should we use?. *BMC Health Serv Res* 12:365. doi: 10.1186/1472-6963-12-365.
25. Maio V, Yuen E, Rabinowitz C, Louis D, Jimbo M, et al. (2005) Using pharmacy data to identify those with chronic conditions in Emilia Romagna, Italy. *J Health Serv Res Policy* 10:232–238. doi: 10.1258/135581905774414259.
26. Wiréhn AB, Karlsson HM, Carstensen JM (2007) Estimating disease prevalence using a population-based administrative healthcare database. *Scand J Public Health* 35:424–431. doi: 10.1080/14034940701195230.
27. Barnett K, Mercer SW, Norbury M, Watt G, Wyke S, et al. (2012) Epidemiology of multimorbidity and implications for health care, research, and medical education: a cross-sectional study. *The Lancet* 380: 37–43. doi:10.1016/S0140-6736(12)60240-2.
28. Domínguez-Berjón MF, Borrell C, Cano-Serral G, Esnaola S, Nolasco A, et al. (2008) [Constructing a deprivation index based on census data in large Spanish cities (the MEDEA project)]. *Gac Sanit* 22: 179–187.
29. Basu A, Manning WG (2009) Issues for the next generation of health care cost analyses. *S109–114*.
30. Basu A, Rathouz PJ (2005) Estimating marginal and incremental effects on health outcomes using flexible link and variance function models. *Biostat* 6: 93–109. doi:10.1093/biostatistics/kxh020.
31. Chen AY, Escarce JJ (2010) Family structure and childhood obesity, Early Childhood Longitudinal Study - Kindergarten Cohort. *Prev Chronic Dis* 7: A50.
32. Fitzmaurice GM, Laird Ware (2011) Applied longitudinal analysis. Hoboken, N.J.: Wiley.
33. Manning WG, Basu A, Mullahy J (2005) Generalized modeling approaches to risk adjustment of skewed outcomes data. 465–488.
34. Ramsey S, Willke R, Briggs A, Brown R, Buxton M, et al. (2005) Good research practices for cost-effectiveness analysis alongside clinical trials: the ISPOR RCT-CEA Task Force report. 521–533.
35. Martínez-Granado M, Greño P, Oleaga M (2012) The Basque Country, Spain: Self-Evaluation Report, OECD Reviews of Higher Education in Regional and City Development. Available: <https://www1.oecd.org/edu/highereducationandadultlearning/Basque%20Country%20Self%20Evaluation%20Report.pdf>. Accessed 14 May 2013.
36. Gené-Badía J, Gallo P, Hernández-Quevedo C, García-Armesto S (2012) Spanish health care cuts: penny wise and pound foolish? *Health Policy* 106: 23–28. doi:10.1016/j.healthpol.2012.02.001.
37. Hjerpe P, Merlo J, Ohlsson H, Bengtsson Boström K, Lindblad U (2010) Validity of registration of ICD codes and prescriptions in a research database in Swedish primary care: a cross-sectional study in Skaraborg primary care database. *BMC Med Inform Decis Mak* 10: 23. doi:10.1186/1472-6947-10-23.
38. Cabrera-León A, Jadad AR, Nuño-Solinis R, Bernabéu-Wittel M, Morales-Asencio JM, et al. (2012) Improving care for people living with chronic diseases: Innovative examples from Spain. *International Journal of Healthcare Management* 5: 208–215. doi:10.1179/2047971912Y.0000000022.
39. Nuño Solinis R, Contel Segura JC, Orueta JF, García-Álvarez A, Lewis G (2013) Solinis and implementation of risk stratification tools. Available: http://oberri.org/wp-content/uploads/2013/03/Stratification_monography.pdf. Accessed 14 May 2013.
40. Lewis GH (2010) "Impactability models": identifying the subgroup of high-risk patients most amenable to hospital-avoidance programs. *Milbank Q* 88: 240–255. doi:10.1111/j.1468-0009.2010.00597.x.

Acknowledgments

We thank the MEDEA research team in the Basque Country for the calculation and provision of the deprivation index. At the same time we want to explicitly thank Montse Calvo for her work in geocoding the data.

Author Contributions

Conceived and designed the experiments: JFO AGA MGG FP RNS. Performed the experiments: JFO. Analyzed the data: AGA. Wrote the paper: MGG JFO. Participated in interpretation of data, critically reviewed and gave final approval to the manuscript: JFO AGA MGG FP RNS.

Referencias bibliográficas: (1,11,16,65,98,106,108,112,114,145–173)

**3.2 OBJETIVO 2: DETERMINAR LA VALIDEZ DE LOS SISTEMAS DE AJUSTE DE RIEGO POBLACIONAL
EN NUESTRO MEDIO**

Publicado como:

Orueta JF, Nuño-Solinis R, Mateos M, Vergara I, Grandes G, Esnaola S. Predictive risk modelling in the Spanish population: a cross-sectional study. BMC Health Serv Res. 2013;13:269. (174)

RESEARCH ARTICLE

Open Access

Predictive risk modelling in the Spanish population: a cross-sectional study

Juan F Orueta^{1*}, Roberto Nuño-Solinis^{2†}, Maider Mateos^{2†}, Itziar Vergara^{1†}, Gonzalo Grandes^{1†} and Santiago Esnaola^{3†}

Abstract

Background: An increase in chronic conditions is currently the greatest threat to human health and to the sustainability of health systems. Risk adjustment systems may enable population stratification programmes to be developed and become instrumental in implementing new models of care.

The objectives of this study are to evaluate the capability of ACG-PM, DCG-HCC and CRG-based models to predict healthcare costs and identify patients that will be high consumers and to analyse changes to predictive capacity when socio-economic variables are added.

Methods: This cross-sectional study used data of all Basque Country citizens over 14 years of age ($n = 1,964,337$) collected in a period of 2 years. Data from the first 12 months (age, sex, area deprivation index, diagnoses, procedures, prescriptions and previous cost) were used to construct the explanatory variables. The ability of models to predict healthcare costs in the following 12 months was assessed using the coefficient of determination and to identify the patients with highest costs by means of receiver operating characteristic (ROC) curve analysis.

Results: The coefficients of determination ranged from 0.18 to 0.21 for diagnosis-based models, 0.17-0.18 for prescription-based and 0.21-0.24 for the combination of both. The observed area under the ROC curve was 0.78-0.86 (identifying patients with a cost higher than P-95) and 0.83-0.90 (P-99). The values of the DCG-HCC models are slightly higher and those of the CRG models are lower, although prescription information could not be used in the latter. On adding previous cost data, differences between the three systems decrease appreciably. Inclusion of the deprivation index led to only marginal improvements in explanatory power.

Conclusion: The case-mix systems developed in the USA can be useful in a publicly financed healthcare system with universal coverage to identify people at risk of high health resource consumption and whose situation is potentially preventable through proactive interventions.

Keywords: Risk-adjustment, Burden of illness, Actuarial prediction, Health risk stratification

Background

Increased life expectancy combined with other factors has produced a progressive increase in the prevalence of chronic diseases and multimorbidity situations, especially in the older population strata. However, current healthcare systems were designed to serve primarily acute episodes of illness and have trouble meeting the complex healthcare needs that this group of people present [1]. In addition, a small number of patients with

multiple pathologies requires such a high number of recurrent hospitalisations and other costly treatments that the cost of their care accounts for the majority of the budgets of health organisations.

In this context, in 2010 the Basque Government's Department of Health published a Strategy to tackle the challenge of Chronicity in the Basque Country [2], containing a series of policies and projects to reinvent the healthcare delivery model and adapt it to this new situation. In order for interventions to be effective and efficient, they should be implemented among those patients whose care needs match the profile for which they were designed. This fact raises the need to develop a

* Correspondence: jon.orueta@osakidetza.net

†Equal contributors

¹Osakidetza, Basque Health Service, Bilbao, Spain

Full list of author information is available at the end of the article

population stratification system based on risk adjustment mechanisms.

The risk adjustment models use information obtained from patients to explain the variation in healthcare resource consumption, cost and the outcomes of the care they receive. To do this, models were developed using different explanatory variables such as demographics, past consumption of health resources and health status [3-7]. Incorporating clinical variables generates greater explanatory power. Moreover, systems that contain these variables are easier to interpret for the healthcare professionals responsible for caring for these patients.

Among the best-known predictive instruments are Adjusted Clinical Groups (ACG-PM) [8], Diagnostic Cost Groups/Hierarchical Condition Categories (DCG-HCC) [9] and Clinical Risk Groups (CRG) [10]. All three were designed in the U.S., and are robust systems from a statistical point of view and versatile in their applications. Their usefulness has been proven in public and private health organisations over a number of years. They are able to explain a large portion of the variability in a population's use of health services and to provide a forecast estimate of the volume of healthcare resources that each individual will require the following year. The most recent versions combine information about diagnoses, prescriptions, previous cost and use of certain procedures.

Despite their undeniable appeal, these instruments also have some limitations resulting from their failure to include other factors that influence health, such as lifestyle, socio-economic variables and other factors relating to the social environment [11,12].

There may also be doubts about the validity and applicability of these instruments in our setting. Although several studies have demonstrated the ability of diagnosis-based case-mixes to retrospectively explain the use of health resources in Spain [13,14] and other countries, there are few references comparing different predictive tools in a national system similar to ours. In addition, the limited development of health databases for administrative purposes in Spain may pose obstacles to the implementation of risk prediction models.

This paper has two objectives. First, to verify the validity of ACG-PM, DCG-HCC and CRG systems in terms of predicting healthcare costs and identifying in advance those patients that will consume a high level of resources the following year; and second, to analyse the potential improvement in the predictive capacity of these instruments when variables related to patients' socio-economic status are incorporated.

Methods

This is a cross-sectional study carried out within the health system of the Basque Country (Spain). The Spanish National Health System (SNS) provides universal coverage.

This coverage and the benefits package are common to Spanish citizens and foreign nationals within Spanish national territory.

The SNS is publicly funded through general taxes. At the point of delivery, provision is free of charge, with the exception of pharmaceuticals prescribed, which entail a co-payment.

The regional organizational structure is the result of a devolution process. Geopolitically, Spain is made up of 17 regions referred to as Autonomous Communities. The 17 regional health ministries have primary control over the funding, organization, and delivery of health services within their territory. These competencies were transferred over the past 30 years and, in particular, the Basque Health Service, called *Osakidetza*, was created in 1983.

In the Basque Country, there is a purchaser provider split, with the Department of Health and Consumer Affairs of the Basque Government being responsible for policy making, for public health and for planning and financing health care. *Osakidetza* is the only public provider of health services in the region, including primary care, hospital care (both acute and long-term care), specialist outpatient clinics, emergencies, and mental health. All health professionals in *Osakidetza* are salaried.

Primary Care is structured in Primary Care Areas, in which primary care is provided through one or more Health Centers under criteria designed to achieve a balance between optimum accessibility and managerial efficiency. There are a total of 1835 doctors working in primary care (1544 general practitioners [GPs] and 291 pediatricians); they work in teams and act as gatekeepers for the other levels of care. Each citizen is on the list of a given primary care doctor and nurse [15].

The study population was composed of all persons over 14 years of age, registered in *Osakidetza* on 1 September 2008. The study period corresponds to two consecutive 12-month intervals. Data from the first year (01 September 2007 to 31 August 2008) were used to develop the explanatory variables and those from the second year (01 September 2008 to 31 August 2009) for the response variables. A minimum monitoring period was established in the first year, including only those people that were assigned to a doctor in *Osakidetza* for at least 6 months, regardless of whether or not they had any contact with the health services ($n = 1,973,971$). Of these, 28,182 people did not complete the second follow-up year due to death ($n = 18,548$), transfer or other causes ($n = 9,634$). Those citizens in the study population who died during the second year were included, whereas those who withdrew for other reasons were not. As such, the final population consisted of 1,964,337.

Sources of information

Case-mix systems are used in the USA to classify the population from claim data. Since this information system is not operative in Spain, data were extracted from the available sources. For this study, we obtained permission from the Basque Health Service to use the Basque Country population stratification program (PREST) database. PREST uses an opaque identifier to ensure patient confidentiality and contains information from primary care electronic medical records (PC-EMR), minimum basic data set of hospital discharge reports (MBDS) and computerised files from day hospitals, emergency departments and specialised outpatient offices. These data were as follows:

- Demographic data: age, sex and census area of residence
- ICD-9-CM codes for diagnoses from each contact with primary care, hospital admissions and day hospitals. The latter two also contained information on procedures. The coding is done in hospitals by clinical documentation specialists, but in primary care the doctors themselves must perform this task when establishing or modifying a diagnosis. A more detailed description of this process can be found elsewhere [16]. In order to avoid the possible inclusion of long-term diseases that were not currently active, we only included the diseases that were considered reason for encounter, according to the annotations of the physicians, and involved in some clinical action, such as cause of prescription, new clinical notation or derived visit, during the period of study.
- Prescriptions in primary care, which are coded automatically in the PC-EMRs according to the World Health Organization (WHO) Anatomical Therapeutic Chemical (ATC) system [17].

Regarding the cost, this was obtained directly for primary care prescriptions recorded in PC-EMR. In the other cases (visits to emergency departments, outpatient specialty care and primary care doctors and nurses; lab tests and X-rays requested in primary care; some procedures such as dialysis, radiation therapy or chemotherapy performed in day hospitals) the number of services provided to each patient was multiplied by their standard cost (the average cost of each service provided to a patient treated in Osakidetza, according to calculations made by the aforementioned organisation). The costs of hospital stays and major outpatient surgical procedures were calculated according to the weights of their corresponding Diagnosis Related Groups (DRGs). Services for which no information was available were excluded from the cost estimate: Mental Health (both admissions and

outpatient visits), hospital-at-home services and day hospitals (except the above-mentioned procedures), outpatient rehabilitation, medical transport, prostheses and other equipment delivered to patients at home. It was estimated that the total cost of excluded services corresponded to 28.2% of the overall budget.

The deprivation index of the census tract (median population size = 1,200 inhabitants) of residence proposed by the MEDEA project [18] was used as a proxy of individual socioeconomic position. Five simple indicators were included in this index (year 2001): Unemployment, low educational level, low educational level in young people (16–29 years), manual workers, and temporary workers. The deprivation index was categorised in quintiles.

Classification systems for patients

ACG-PM version 9.0, CRG version 1.6 and DCG-HCC (models ID#26, ID#69 and ID#71) were used for this study. A brief description of them can be found as Additional file 1:

- CRGs [10] is a cell-based model in which each person is assigned to one mutually exclusive category, based on clinical criteria; the total number of CRGs is 1,076. In this study it was not possible to add information on prescriptions, since the Basque country organisation uses the WHO ATC system, which is rejected by the CRG v1.6 software.
- DCG-HCC [9] are a regression-model. All diagnoses and prescriptions are classified into clinically homogeneous groups that are employed to predict the cost of each patient. In this study, 117 categories for diagnoses and 203 for prescriptions were included as independent variables.
- ACG-PM [8] adopts a mixed approach. Patients are categorised in mutually exclusive categories, of which the model uses 34. Other markers are incorporated alongside them, with the complete model comprising 180 variables generated from diagnoses and 65 from prescriptions.

Statistical models

From the information obtained with the use of the three case-mixes, several regression models were constructed using the cost of the second year as the outcome variable. To avoid overfitting problems and to confirm that the results do not depend on the sample, a fivefold cross validation was carried out. Thus, the sample was split into five random subsamples and model fitting was performed five times, considering four of these subsamples as the training set, and the remaining one as the test set, each time. The statistics employed to evaluate and

compare the performance of the different models were derived from this cross validation.

The coefficient of determination R² was used to measure the explanatory power. First, adjustments were made to models whose independent variables were the out-of-the-box risk scores offered directly by the case-mix developers. Then multiple regression models were recalibrated to our population dataset, in which clinical variables (groups based on diagnoses or drugs from the case-mix), previous cost and socio-economic variables (deprivation index) were successively added to the demographic variables (age and sex).

OLS (Ordinary Least Squares) statistical models do not adequately match the analysed data, as none of the variables follows a normal distribution and additionally, they do not take into account the hierarchical nature of the data (patients grouped in lists of primary care doctors, those working in health centres and centres clustered in health districts). Therefore, two-part models and hierarchical models were also used, including the 3 levels of grouping listed above. Because these models do not directly provide an R², their results were compared with those obtained by OLS using MAPE (Mean Absolute Prediction Error), expressed as a percentage (dividing the obtained value by the observed average cost).

In order to check the validity of these systems to identify people that will require high resource consumption the following year, logistic regression models were developed in which the dependent variables indicate whether the person belongs to 5% and 1% of highest-consuming patients during the second period. The explanatory variables were the same as in the linear models described above and the area under the ROC curve was the measure used to evaluate and compare the different models.

Results

Of the study population, 51.2% are women and 21.5% are aged over 65 years. The distribution of the population in age and sex groups, and the averages for unique prescriptions and diagnoses per patient can be found in Table 1. More than three quarters of the population had at least one contact with health services and over 7% required one or more hospitalisations per year. The overall average annual consultations per patient ranged between 0.31-0.32 for emergencies, 1.70-1.76 for outpatient specialty care, 4.29-4.47 for primary care doctors and 1.69-2.09 for nursing consultations. A table in Additional file 2 the distribution of these averages by age group.

Table 2 shows the results obtained by different linear regression models in terms of R [2]. While the age and sex-based models explained 7% of the cost variability, the out-of-the-box models reached values between 13.5% and 20.8%. Regarding those that were recalibrated with our data, the coefficients of determination ranged from 0.18 to 0.21 for diagnosis-based models, 0.17-0.18 for prescription-based and 0.21-0.24 for the combination of both. In all cases the values of the DCG-HCC models are slightly higher and those of the CRG models lower, although prescription information could not be used in the latter. When data on the cost of the previous year is added, differences between the three systems decreased appreciably.

Table 3 compares the MAPE of the OLS, two-part and hierarchical models. The two-part model shows the worst results and the differences between the OLS and hierarchical models are small and in both directions.

With regard to the models' capability to correctly identify patients located above the 95th and 99th percentiles, the results are presented in Tables 4 and 5. The out-of-the-box models for the three case mixes produce different AUC values: those for the CRG models are similar

Table 1 Distribution of the population in age and sex groups and descriptive information on diagnoses and prescriptions

Age groups	Men N (%)	Women N (%)	Mean unique diagnoses per patient	% Patients with one or more diagnosis	Mean drugs prescribed (unique ATC codes) per patient	Patients with one or more drugs prescribed
14-24	104,686 (5.33%)	99,969 (5.09%)	1.58	52.06%	1.98	65.69%
25-34	178,767 (9.10%)	171,317 (8.72%)	1.73	51.97%	2.12	64.46%
35-44	194,187 (9.89%)	187,426 (9.54%)	1.93	52.77%	2.20	64.04%
45-54	164,620 (8.38%)	165,997 (8.45%)	2.55	58.28%	2.56	67.01%
55-64	135,889 (6.92%)	138,760 (7.06%)	4.29	73.33%	3.54	77.06%
65-74	95,032 (4.84%)	107,207 (5.46%)	6.54	84.62%	4.63	84.06%
75-84	67,272 (3.42%)	95,343 (4.85%)	7.88	86.48%	5.45	85.34%
85+	17,091 (0.87%)	40,774 (2.08%)	6.54	72.44%	4.60	72.38%
Total	957,544 (48.75%)	1,006,793 (51.25%)	3.00	63.01%	3.40	70.68%

Table 2 Coefficients of determination (R2) for the case-mix based models to predict the health cost per patient

		Demographic variables only	ACG-PM	CRG	DCG-HCC
Out of the box	Variables:				
	A&S + dx + rx + cost percentiles (age < 65)		0,167		
	A&S + dx + rx + cost percentiles (age 65+)		0,164		
	A&S + dx			0,135	
	A&S + dx + cost				0,181
	A&S + dx + rx + cost				0,208
Recalibration	Variables				
	Age and Sex (A&S):	0,071			
	A&S + Only Dx		0,182	0,181	0,213
	A&S + Only Rx		0,165	-	0,178
	A&S + Dx + Rx		0,211	-	0,236
	A&S + Dx + Rx + cost percentile		0,231	0,218*	0,246
	A&S + Dx + Rx + cost		0,260	0,254*	0,269
	A&S + Dx + Rx + cost + DI		0,260	0,254*	0,269

*The CRG models do not include prescriptions.

Age groups: 14–17; 18–34; 35–44; 45–54; 55–64; 65–69; 70–74; 75–79; 80–84; 85 + .

Cost groups in percentiles: 0–1; 2–10; 11–25; 26–50; 51–75; 76–90; 91–93; 94–95; 96–97; 98 + .

Dx diagnoses, Rx prescriptions, DI Deprivation index.

to those that use only age and sex and the same applies to the ACG model for patients over 65; the values from the ACG model for younger patients are higher than both of the above, but the highest of all are derived from the DCG-HCC models. In the case of the recalibrated models, the AUC values for the DCG-HCC and ACG-based models display similar behaviour and the AUC values from CRG models are lower.

The inclusion of the deprivation index resulted in a marginal improvement in the coefficients of determination for cost prediction or AUC for identifying patients with high needs.

Discussion

Our study has revealed that the three case-mix systems used (ACG-PM, CRG and DCG-HCC) show sufficient capability to predict use of health resources and identify

people with high needs over the next 12 months in an environment other than that for which they were designed and using other sources of information, namely, a publicly-funded universal coverage system and in the absence of an information system based on the use of claim data.

While age and sex can predict 7% of the variability in cost, models that use clinical variables can predict three times this amount and, when prior costs are added, this value is even higher, reaching 27%. In this case, the observed increase in the coefficients on addition of the deprivation index was very small. Moreover, out-of-the-box models would seem to be a reasonable alternative for use in situations such as organisations that serve small populations or that lack sufficient data for self calibration. DCG-based models provided slightly higher explanatory power and the inability to use prescriptions

Table 3 MAPE (Mean absolute prediction error) expressed as a percentage of the average cost of different models based on case-mix systems, using different regression models

	Linear regression (OLS)			Two-part			Hierarchical models		
	ACG-PM	CRG	DCG-HCC	ACG-PM	CRG	DCG-HCC	ACG-PM	CRG	DCG-HCC
Recalibration Variables									
Age and Sex (A&S)		106.80%		109.09%			106.52%		
A&S + Only Dx	92.36%	96.36%	91.26%	114.59%	104.74%	109.74%	95.27%	95.97%	91.52%
A&S + Only Rx	93.57%		91.87%	113.84%		115.74%	93.74%		91.98%
A&S + Dx + Rx	88.41%		87.02%	114.96%		114.44%	89.87%		87.26%
A&S + Dx + Rx + cost percentile	85.99%	87.70%	85.05%	98.52%	96.11%	97.92%	86.97%	87.72%	85.37%
A&S + Dx + Rx + cost percentile + DI	86.02%	87.70%	85.06%	98.49%	96.09%	97.89%	86.97%	87.72%	85.37%

Dx diagnoses, Rx prescriptions, DI Deprivation index.

Table 4 Area under the receiver operating characteristics (ROC) curve of the case-mix based logistic regression models to identify patients located above the 95th percentile of health spending

Out of the box	Demographic variables only		ACG-PM		CRG		DCG-HCC	
	AUC	95% CI	AUC	95% CI	AUC	95% CI	AUC	95% CI
Variables:								
A&S + dx + rx + cost percentiles (age < 65)			0,816	(0.813 - 0.818)				
A&S + dx + rx + cost percentiles (age 65+)			0,761	(0.760 - 0.764)				
A&S + dx					0,787	(0.786 - 0.789)	0,824	(0.822 - 0.825)
A&S + dx + rx + cost							0,852	(0.851 - 0.853)
Recalibration								
Variables:								
A&S (Age and sex)	0,774	(0.773 - 0.776)						
A&S + Only Dx			0,845	(0.844 - 0.847)	0,797	(0.795 - 0.798)	0,846	(0.845 - 0.848)
A&S + Only Rx			0,833	(0.831 - 0.834)			0,837	(0.836 - 0.838)
A&S + Dx + Rx			0,847	(0.853 - 0.856)			0,858	(0.857 - 0.859)
A&S + Dx + Rx + cost percentile			0,868	(0.866 - 0.869)	0,848*	(0.847 - 0.849)	0,868	(0.867 - 0.869)
A&S + Dx + Rx + cost percentile + DI			0,868	(0.867 - 0.869)	0,848*	(0.847 - 0.850)	0,868	

*The CRG models do not include prescriptions.

Age groups: 14-17; 18-34; 35-44; 45-54; 55-64; 65-69; 70-74; 75-79; 80-84; 85 + .

Cost groups in percentiles: 0-1; 2-10; 11-25; 26-50; 51-75; 76-90; 91-93; 94-95; 96-97; 98 + .

Dx diagnoses, Rx Prescriptions, DI Deprivation index.

data in the CRG software was a limitation for making comparisons with the latter. In this study, the use of more complex statistical models than OLS did not provide any benefits.

As regards the ability of models to correctly detect people that require large amounts of health resources, the ACG-PM and DCG-HCC results are relatively

similar and are higher than those from CRG. However, regarding the out-of-the-box option, the DCG-HCC models show a better behaviour.

This is the first study to compare three case-mix systems in an entire geographical area, including some social variables. Moreover, unlike other studies conducted in Europe [19,20], it combines patient information from

Table 5 Area under the receiver operating characteristics (ROC) curve of the case-mix based logistic regression models to identify patients located above the 99th percentile of health spending

Out of the box	Demographic variables only		ACG-PM		CRG		DCG-HCC	
	AUC	95% CI	AUC	95% CI	AUC	95% CI	AUC	95% CI
Variables:								
A&S + dx + rx + cost percentiles (age < 65)			0,852	(0.847 - 0.857)				
A&S + dx + rx + cost percentiles (age 65+)			0,779	(0.774 - 0.783)				
A&S + dx					0,814	(0.811 - 0.818)	0,858	(0.8556 - 0.861)
A&S + dx + rx + cost							0,882	(0.880 - 0.885)
Recalibration								
Variables:								
A&S (Age and sex)	0,811	(0.809 - 0.814)						
A&S + Only Dx			0,882	(0.880 - 0.884)	0,829	(0.826 - 0.832)	0,884	(0.882 - 0.886)
A&S + Only Rx			0,862	(0.859 - 0.864)			0,865	(0.863 - 0.868)
A&S + Dx + Rx			0,889	(0.887 - 0.891)			0,892	(0.890 - 0.894)
A&S + Dx + Rx + cost percentile			0,897	(0.895 - 0.899)	0,869*	(0.866 - 0.871)	0,899	(0.897 - 0.901)
A&S + Dx + Rx + cost percentile + DI			0,897	(0.895 - 0.899)	0,869*	(0.866 - 0.872)	0,899	(0.897 - 0.902)

*The CRG models do not include prescriptions.

Age groups: 14-17; 18-34; 35-44; 45-54; 55-64; 65-69; 70-74; 75-79; 80-84; 85 + .

Cost groups in percentiles: 0-1; 2-10; 11-25; 26-50; 51-75; 76-90; 91-93; 94-95; 96-97; 98 + .

Dx diagnoses, Rx prescriptions, DI Deprivation index.

various sources: primary care, hospital admissions and specialist outpatient care.

However, some limitations should be noted. First, our healthcare system has no direct cost-per-patient data; these had to be calculated from the standard prices of provided services and in some cases (principally mental health, rehabilitation, hospital at home and some aspects of day hospital) they could not be obtained.

Moreover, the information sources used are sufficiently complete for obtaining information on diagnoses in hospitalised patients, but not in patients treated in outpatient specialty care or the hospital emergency department. With regard to primary care, as is the case elsewhere, in the Basque Country there is a degree of underreporting of diagnoses and prescriptions in EMRs. Also, diagnoses registered only once were accepted, which may have meant that some annotation or coding errors by doctors was overlooked. However, records of primary care doctors tend to suffer from a lack of sensitivity [21] but not specificity, so we do not consider that this would have exerted a significant effect. In any case, although it is known that the quality of diagnosis [22] and prescription [23] information does influence results, there is no reason to believe that these issues are important enough to significantly affect our results, especially given that a requirement of these adjustment models is their ability to work with imperfect data in the real world [3,4]. The use of population adjustment systems requires the application of administrative databases and other sources of information containing data collected for other purposes, whose limitations are known [24,25] and it is assumed that even in major chronic diseases, for a proportion of patients receiving diagnoses in a year, this information is not repeated in the codes extracted during the following year [3,26].

Finally, a third limitation refers to the social variable used (deprivation index) which, given its ecological character, may underestimate the contribution of individual socioeconomic characteristics.

Our results agree with those found by other authors and support the robustness of these case-mix systems [4,6,27]. They display comparable results despite having been conducted in countries with different types of health systems, groups of people with different characteristics to those of the general population or using different scenarios for analysis, such as truncation of costs above a certain threshold. In our case, no transformation was performed on data to achieve a better fit. No patient was excluded for not being a healthcare user and neither were those who, due to death, did not complete the second year. Although it is commonly accepted that regression-based models are more flexible and predict better than those that are cell-based [4-6], in our case the classification of the population based on diagnoses

by CGR categories shows a similar predictive ability to the ACG-PM system, which uses a mixed system of categories and regression.

Beyond the predictive capability of the models, other considerations must be taken into account when assessing a case-mix, such as transparency of their classification methods and their ability to provide useful information from a clinical and not just financial point of view. Although some simple methods, such as the number of conditions or medications [28,29] have been used as a disease burden measure and, in some cases, to predict mortality, health care costs, number of visits or other variables. Nevertheless, models based on these methods would have limited implementation given that they do not provide a comprehensive approach to the actual population's burden of diseases. Additionally, any estimation based on such models would be seriously affected by the variability in clinical practice patterns among clinical practitioners.

All three systems, employed in our study, categorise the diagnoses into clinically relevant groups (260 ACG-PM, 547 CRG and 1,013 DCG) which in turn can easily be collapsed into a smaller number of groups and show a sufficient degree of granularity. The use of these groups, instead of all the registered ICD-9-CM codes, can decrease the influence of the diagnosis coding practices and also provide a manageable number of groups to identify patients with a given disease or observe the distribution of diseases in population subgroups. The DCG-HCC and ACG-PM systems also include an additional method to identify diseases, based on prescriptions. The records of prescribed medication provide a list of diseases that are being treated, which in our case has been particularly useful for obtaining data from patients who only visit their primary care doctor to get prescriptions, because their condition is stable or because their disease is receiving care in outpatient specialised care facilities. Moreover, the coding of drugs is carried out automatically, which minimises errors and prevents manipulation by clinicians.

In contrast to USA [30] or other European countries [31], in a national health system such as the Basque Country, where the component organisations provide healthcare to all the residents in a geographical area and the competition between them is very limited, the hazard of perverse patient selection practices is impossible. However, risk stratification systems have other applications, such as identification of patients eligible for case-disease and case-management programs. These interventions are designed to improve the quality and efficiency of care, especially those who are at risk of having high future care needs. In any case, identification of the latter group will be of little interest, unless within it those patients can be differentiated whose deterioration

can be avoided or mitigated by proactive actions by those that are in unmanageable situations. While previous cost displays high explanatory power, it is strongly influenced by factors other than healthcare needs [32,33] and, except when used as a complement to clinical variables, it does not enable the identification of target populations.

An imperative for the implementation of health programmes is that the entire population benefit. Although case-mix systems use multiple clinical data, other variables such as social variables also influence people's health and care outcomes. For this reason, a system that considers future care needs based on information from prior use may be unfair if there are social groups whose access to health services is less than their actual need [34]. Consequently, doubts could be raised about ethical issues surrounding the implementation of population stratification, based on the possibility of engendering subtle discrimination against patients in a more severe state of deprivation. In our study, inclusion of the deprivation index did not produce a significant difference in the models' ability, which is in line with another study carried out in Canada using administrative and survey data to predict the number of doctor visits [35]. In any case, maintaining the social variables is justified as a means of ensuring greater equity in patient selection [36].

This study analysed the predictive ability of models based primarily on diagnoses and prescriptions in the total population over 14 years of age in a geographical region. However, in order to implement management programmes for specific diseases, it would be appropriate to also know the capability of these models when applied to subgroups of patients diagnosed with these diseases. Furthermore, from the implementation of Health Information Technologies (HIT), new data can be obtained that until now were not accessible [37], such as data on following clinical practice guidelines, patient treatment adherence, life habits and risk factors, the incorporation of which will allow a better description of the health of the population and could improve the ability of predictive models.

Conclusion

Our study has shown that case-mix systems developed in the U.S. can be used in a publicly financed healthcare system with universal health insurance such as that of the Basque Country, to predict consumption of health resources. Also, the additional use of information from diagnoses and prescriptions mitigates some of the limitations attributable to the information systems in use and produces better results. The use of these systems allows the identification of people at risk of requiring high health resource consumption in the future and whose

situation is potentially preventable through the implementation of proactive interventions.

Additional files

Additional file 1: Classification systems for patients analysed in the study.

Additional file 2: Mean values per patient of admissions, specialised and primary care visits, by age groups.

Abbreviations

ACG-PM: Adjusted Clinical Groups – predictive modelling; ATC: Anatomical Therapeutic Chemical system; AUC: Area under curve; CRG: Clinical Risk Groups; DCG-HCC: Diagnostic Cost Groups/Hierarchical Condition Categories; HIT: Health Information Technologies; ICD-9-CM: International Classification of Diseases, 9th Revision, Clinical Modification; MAPE: Mean Absolute Prediction Error; OLS: Ordinary Least Squares; ROC: Receiver operating characteristic.

Competing interests

The authors declare that they have no competing interests.

Authors' contributions

All authors participated in the design of the study. JFO performed the validation of databases. MM was responsible for statistical analyses. JFO wrote the draft of manuscript. All authors participate in interpretation of data, critically reviewed and gave final approval to the manuscript.

Author details

¹Osakidetza, Basque Health Service, Bilbao, Spain. ²O + berri, Basque Institute for Healthcare Innovation, Plaza Asua 1, 48150, Sondika, Spain. ³Department of Health and Consumer Affairs, Basque Government, Vitoria, Spain.

Received: 18 September 2012 Accepted: 6 July 2013

Published: 9 July 2013

References

1. Boyd CM, Fortin M: **Future of multimorbidity research: how should understanding of multimorbidity inform health system design?** *Public Health Rev* 2010, **32**:451–474.
2. Department of Health and Consumer Affairs of the Basque Government: *A strategy to tackle the challenge of chronicity in the Basque Country*. Vitoria, Spain; 2010. Available at: <http://cronicidad.blog.euskadi.net/descargas/plan/ChronicityBasqueCountry.pdf>. Accessed August 21, 2012.
3. Ellis R: **Risk adjustment in Health care markets**. In *Financing Health Care: New Ideas for a Changing Society*. Edited by Lu M, Jonsson E, Weinheim, RFG: Wiley-VCH; 2007:177–219.
4. Winkelman R, Mehmud S: *A Comparative Analysis of Claims-Based Tools for Health Risk Assessment*. 2007. Available at: <http://www.soa.org/Files/Research/Projects/risk-assessmentc.pdf>. Accessed June 16, 2012.
5. Rakovski CC, Rosen AK, Wang F, Berlowitz DR: **Predicting Elderly at Risk of Increased Future Healthcare Use: How Much Does Diagnostic Information Add to Prior Utilization?** *Health Serv Outcomes Res Methodol* 2002, **3**:267–277.
6. Weir S, Awah G, Clark RE: **Case selection for a Medicaid chronic care management program**. *Health Care Financ Rev* 2008, **30**:61–74.
7. DeSalvo KB, Jones TM, Peabody J, McDonald J, Fihn S, Fan V, He J, Muntner P: **Health care expenditure prediction with a single item, self-rated health measure**. *Med Care* 2009, **47**(4):440–447.
8. Johns Hopkins University, School of Public Health: *The Johns Hopkins University ACG Case-Mix System*. Internet address: http://www.acg.jhsph.org/index.php?option=com_content&view=article&id=46&Itemid=61. Accessed August 21, 2012.
9. *Verisk Health's DxCG DCG Methodology*. Internet address: <http://www.dxcg.com/resources/library>. Accessed August 21, 2012.
10. *3M™ Clinical Risk Grouping Software*. Internet address: http://solutions.3m.com/wps/portal/3M/en_US/3M_Health_Information_Systems/HIS/Products/CRG/.
11. Rosen AK, Reid R, Broemeling AM, Rakovski CC: **Applying a Risk-Adjustment Framework to Primary Care: Can We Improve on Existing Measures?** *Ann Fam Med* 2003, **1**:44–51.

12. Thomas AJ, Eberly LE, Davey Smith G, Neaton JD: **Multiple Risk Factor Intervention Trial (MRFIT) Research Group. ZIP-code-based versus tract-based income measures as long-term risk-adjusted mortality predictors.** *Am J Epidemiol* 2006, **164**:586–590.
13. Orueta JF, Urraca J, Berraondo I, Darpón J, Aurrekoetxea JJ: **Adjusted Clinical Groups (ACGs) explain the utilization of primary care in Spain based on information registered in the medical records: a cross-sectional study.** *Health Policy* 2006, **76**:38–48.
14. Sicras-Mainar A, Navarro-Artieda R: **Grupo de estudio ACG-BSA. Validación retrospectiva del Johns-Hopkins ACG Case-Mix System en la población Española.** *Gac Sanit* 2009, **23**:228–231.
15. Nuño-Solinis R, Orueta JF, Mateos M: **An answer to chronicity in the Basque Country: primary care-based population health management.** *J Ambul Care Manage* 2012, **35**:167–173.
16. Orueta JF, Urraca J, Berraondo I, Darpón J: **Can primary care physicians use the ICD-9-CM? An evaluation of the quality of diagnosis coding in computerized medical records.** *Gac Sanit* 2006, **20**(3):194–201. Spanish.
17. The WHO Collaborating Centre for Drug Statistics Methodology: **The WHO Collaborating Centre for Drug Statistics Methodology: International language for drug utilization research ATC/DDD.** 2012. Available at: <http://www.whocc.no/>. Accessed April 18, 2012.
18. Domínguez-Berjón MF, Borrell C, Cano-Serral G, Esnaola S, Nolasco A, Pasarín MI, Ramis R, Saurina C, Escolar-Pujolar A: **Construcción de un índice de privación a partir de datos censales en grandes ciudades españolas: (MEDEA Project).** *Gac Sanit* 2008, **22**:179–187.
19. Behrend C, Buchner F, Happich M, Holle R, Reitmeir P, Wasem J: **Risk-adjusted capitation payments: how well do principal inpatient diagnosis-based models work in the German situation? Results from a large data set.** *Eur J Health Econ* 2007, **8**:31–39.
20. van Kleef RC, van Vliet RC: **Improving risk equalization using multiple-year high cost as a health indicator.** *Med Care* 2012, **50**:140–144.
21. Barnett K, Mercer SW, Norbury M, Watt G, Wyke S, Guthrie B: **Epidemiology of multimorbidity and implications for health care, research, and medical education: a cross-sectional study.** *Lancet* 2012. Epub ahead of print.
22. Fleishman JA, Cohen JW: **Using information on clinical conditions to predict high-cost patients.** *Health Serv Res* 2010, **45**:532–552.
23. Kuo RN, Dong YH, Liu JP, Chang CH, Shau WY, Lai MS: **Predicting healthcare utilization using a pharmacy-based metric with the WHO's Anatomic Therapeutic Chemical algorithm.** *Med Care* 2011, **49**:1031–1039.
24. Riley GF: **Administrative and claims records as sources of health care cost data.** *Med Care* 2009, **47**:S51–S55.
25. Lix L, Yogendran M, Burchill C, Metge C, McKeen N, Moore D, Bond R: **Defining and Validating Chronic Diseases: An Administrative Data Approach.** Winnipeg: Manitoba Centre for Health Policy; 2006.
26. Frogner BK, Anderson GF, Cohen RA, Abrams C: **Incorporating new research into Medicare risk adjustment.** *Med Care* 2011, **49**:295–300.
27. Meenan RT, Goodman MJ, Fishman PA, Hornbrook MC, O'Keeffe-Rosetti MC, Bachman DJ: **Using risk-adjustment models to identify high-cost risks.** *Med Care* 2003, **41**:1301–1312.
28. Perkins AJ, Kroenke K, Unützer J, Katon W, Williams JW Jr, Hope C, Callahan CM: **Common comorbidity scales were similar in their ability to predict health care costs and mortality.** *J Clin Epidemiol* 2004, **57**:1040–1048.
29. Brilleman SL, Salisbury C: **Comparing measures of multimorbidity to predict outcomes in primary care: a cross sectional study.** *Fam Pract* 2013, **30**(2):172–178. doi:10.1093/fampra/cms060. Epub 2012 Oct 8.
30. Weiner JP, Trish E, Abrams C, Lemke K: **Adjusting for risk selection in state health insurance exchanges will be critically important and feasible, but not easy.** *Health Aff (Millwood)* 2012, **31**:306–315.
31. van de Ven WP, Beck K, Van de Voorde C, Wasem J, Zmora I: **Risk adjustment and risk selection in Europe: 6 years later.** *Health Policy* 2007, **83**:162–179.
32. Monheit AC: **Persistence in health expenditures in the short run: prevalence and consequences.** *Med Care* 2003, **41**:III53–III64.
33. Ash AS, Zhao Y, Ellis RP, Kramer MS: **Finding future high-cost cases: comparing prior cost versus diagnosis-based methods.** *Health Serv Res* 2001, **36**:194–206.
34. Asthana S, Gibson A: **Setting health care capitations through diagnosis-based risk adjustment: a suitable model for the English NHS?** *Health Policy* 2011, **101**:133–139.
35. Sibley LM, Moineddin R, Agha MM, Glazier RH: **Risk adjustment using administrative data-based and survey-derived methods for explaining physician utilization.** *Med Care* 2010, **48**:175–182.
36. Panattoni LE, Vaithianathan R, Ashton T, Lewis GH: **Predictive risk modelling in health: options for New Zealand and Australia.** *Aust Health Rev* 2011, **35**:45–51.
37. Weiner JP, Fowles JB, Chan KS: **New paradigms for measuring clinical performance using electronic health records.** *Int J Qual Health Care* 2012, **24**:200–205.

doi:10.1186/1472-6963-13-269

Cite this article as: Orueta et al.: Predictive risk modelling in the Spanish population: a cross-sectional study. *BMC Health Services Research* 2013 **13**:269.

Submit your next manuscript to BioMed Central and take full advantage of:

- Convenient online submission
- Thorough peer review
- No space constraints or color figure charges
- Immediate publication on acceptance
- Inclusion in PubMed, CAS, Scopus and Google Scholar
- Research which is freely available for redistribution

Submit your manuscript at
www.biomedcentral.com/submit



Referencias bibliográficas:

(147,108,81,82,175,93,176,102,177,105,96,97,103,178,14,115,114,164,179,180,11)

3.3 OBJETIVO 3: EXPLORAR EL PROCESO DE IMPLANTACIÓN DE LA ESTRATIFICACIÓN POBLACIONAL EN EL PAÍS VASCO DESDE EL PUNTO DE VISTA DE LOS CLÍNICOS E IDENTIFICAR ELEMENTOS RELEVANTES, QUE PUDIERAN ACTUAR COMO FACILITADORES O BARRERAS.

Publicado como:

Arce Sauto R, Saenz de Ormijana AS, Orueta JF, Gagnon M-P, Nuño-Solinís R. A qualitative study on clinicians' perceptions about the implementation of a population risk stratification tool in primary care practice of the Basque health service. BMC Fam Pract. 2014;15:150. (181)

RESEARCH ARTICLE

Open Access

A qualitative study on clinicians' perceptions about the implementation of a population risk stratification tool in primary care practice of the Basque Health Service

Regina Sauto Arce¹, Amaia Saenz De Ormijana², Juan F Orueta³, Marie-Pierre Gagnon^{1,4} and Roberto Nuño-Solinís^{1*}

Abstract

Background: A prospective Population Risk Stratification (PRS) tool was first introduced in the public Basque Health Service in 2011, at the level of its several Primary Care (PC) practices. This paper aims at exploring the new tool's implementation process, as experienced by its potential adopters/users, ie. PC clinicians (doctors and nurses). Findings could help guide future PRS implementation strategies.

Methods: Three focus groups exploring clinicians' opinions and experiences related to the PRS tool and its implementation in their daily practice were conducted. A purposive sample of 12 General Practitioners and 11 PC nurses participated in the groups. Discussions were digitally recorded, transcribed verbatim and analysed by two independent researchers using thematic analysis based on Graham et al.'s Knowledge Translation Theory.

Results: Exploring PC clinicians' experience with the new PRS tool, allowed us to identify certain elements working as barriers and facilitators in its implementation process. This series of closely interrelated elements, which emerged as relevant in building up the complex implementation process of the new tool, as experienced by the clinicians, can be grouped into four domains: 1) clinicians' characteristics as potential adopters, 2) clinicians' perceptions of their practice settings where PRS is to be implemented, 3) clinicians' perceptions of the tool, and 4) the implementation strategy used by the PRS promoter.

Conclusions: Lessons from the implementation process under study point at the need to frame the implementation of a new PRS tool within a wider strategy encouraging PC clinicians to orientate their daily practice towards a population health approach. The PRS tool could also improve the perceived utility by its potential adopters, by bringing it closer to the clinicians' needs and practice, and allowing it to become context-sensitive. This would require clinicians being involved from the earliest phases of conceptualisation, design and implementation of the new tool, and mounting efforts to improve communication between clinicians and tool promoters.

Graham et al.'s Knowledge Translation Theory proved a suitable framework to explore the implementation process of a new PRS tool in the public Basque Health Service's PC practice, and hence to identify implementation barriers and facilitators as experienced by the clinicians.

Keywords: Stratification, Population health management, Primary care, Implementation, Knowledge translation, Predictive risk models

* Correspondence: nuno@bioef.org

¹O + berri, Basque Institute for Healthcare Innovation, Torre del BEC, Ronda de Azkue, 1, 48902 Barakaldo, Bizkaia, Spain

Full list of author information is available at the end of the article

Background

This paper explores Primary Care (PC) clinicians' perceptions about the implementation of a prospective Population Risk Stratification (PRS) tool in their daily practice in the public Basque Health Service. Prospective PRS strategies and tools are intended to classify individuals according to their predicted future healthcare needs. Information provided by PRS tools serves then to identify subpopulations holding different levels of risk and morbidity burden. This information can then be used as a first step in the development of a population health management approach [1], through the design and implementation of proactive interventions tailored to the needs of each risk group [2]. In the Basque Health Service, a tool for prospective PRS was first applied to targeting interventions in 2011, in the context of a wider regional strategy to improve chronic care [3,4].

Population covered by the public Basque Health Service (some 2.2 million inhabitants) was stratified using a PRS tool based on the Adjusted Clinical Groups Predictive Model [5]. Following this model, individuals are classified according to the total volume of resources each one of them is predicted to use within the following year. Estimates are based on individuals' demographic data (age and sex), previous 12 months-clinical data (diagnoses and prescriptions), and history of service use and costs. Results are represented in the form of a predictive risk score, which is calculated as the quotient resulting from the division of an individual's predicted health care costs (in euro) by the predicted average costs for all patients covered by the public Basque Health Service. The prospective stratification tool developed in the Basque Country also allows an easy identification of each individual's main health problems and offers an estimation of the risk of hospital admission [6]. The owner of the PRS is the Basque Department of Health, which collects and analyses the data and provides the results to clinicians on an annual basis. In the first stages of implementation, O+berri, the Basque Institute for Healthcare Innovation, was responsible for the design and testing of the PRS. It is expected that in the near future clinicians will be able to perform their own analysis and that the update of the database will be done on a quarterly basis. Patients cannot opt out of the database, and all the information is routinely collected by the public administration.

Information generated by the PRS tool is used to identify target populations who could benefit from specific services and interventions. In particular, at the time the focus groups for the present study (December 2011) were run, information had been used to identify candidate patients for secondary prevention interventions to be carried out in all PC practices, as well as for some pilot programmes on case and disease management

developed in a few PC practices. In particular, the use that had reached all PC practices was a request by managers to prioritise secondary prevention activities on a targeted population formed by patients diagnosed with hypercholesterolaemia, high blood pressure, or type 2 diabetes, not suffering severe comorbidities (based on criteria as detailed in Table 1) [6]. Indicators on preventive activities on the selected target group were included in the assessment framework used by the general management to evaluate performance by PC practices.

General management, as promoter of the new PRS tool, organised informative session with PC unit's managers (on average a PC unit counts with 13 General Practitioners (GPs)) on this first system-wide use of PRS results in PC. These sessions aimed at raising awareness about the stratification tool and its first application (selected target population, performance indicators...). As for the way results were incorporated into clinical information systems, on the one hand, an icon was added onto the electronic health record of each individual in the target population. On the other hand, GPs were regularly sent out a list of target-patients in their panels.

In this context, the present study aims at exploring the implementation process of the new prospective PRS tool in daily practice of PC in the public Basque Health Service. Despite the growing use of risk stratification tools based on predictive models in various healthcare systems [2], we have not been able to find much literature on the processes of implementation of such tools in daily practice. The few studies that were found are: a report on the use of a stratification tool in Wales [7], a qualitative study carried out in Germany [8], and a survey conducted among doctors in Catalonia (Spain) [9]. Work from Wales presents some Primary Care professionals' experiences on testing a specific stratification tool, the paper from Germany explores PC physicians' experiences with case finding through the use of predictive modelling, and the survey in Catalonia explores doctors' (both practising and managers) opinion about the potential

Table 1 Target group of chronic patients with low comorbidity for prioritised secondary preventive activities

Inclusion criteria	Exclusion criteria
<i>Presence of one of the following three diagnoses:</i>	<i>Presence of one of the following two diagnoses:</i>
Type 2 diabetes	Heart failure
High blood pressure	Ischaemic heart disease
Hypercholesterolaemia	
<i>Predicted healthcare needs:</i>	
Age 0–64 years: predictive risk score <2.7	
Age 65 years or more: predictive risk score <1.5	

uses of a risk stratification system and its implementation difficulties. Two other papers put up recommendations concerning the implementation of stratification tools based on researchers' experiences with the use of predictive models [10,11].

The objective of this paper is to identify the elements that, acting as barriers and/or facilitators, emerge as relevant in the implementation process of a new prospective PRS tool in daily practice of PC in the public Basque Health Service. For this purpose, we explored the perceptions and experience of its potential users/adopters, ie. GPs and PC nurses.

Methods

The present study draws on qualitative methods to explore clinicians' perceptions and experiences with the stratification tool implemented in their daily contexts and practices. Qualitative methods are based on an ontological understanding of human realities as complex and plural, which stays in line with basic assumptions of this project: the complexity and plurality of clinicians' contexts and practices, and thus, perceptions and opinions regarding the PRS tool being implemented.

Researchers considered the dialogical method to be the most appropriate for achieving the study objectives. We chose this method because, considering that the tool was still at an early phase of integration in practice, we were highly interested in understanding the contexts and forms in which the clinicians conceived and gave meaning to it. The specific technique used within this dialogical method was the focus group. In contrast to individual interviews, we believed that focused meetings between peers would better respond to the research objectives by providing a comprehensive view of the different positions (social and professional contexts) in relation to the stratification tool and its implementation in practice.

Participants were selected using a theoretical sampling method, guided by the knowledge translation model of Graham et al. [12,13] and the findings of previous research in the field of implementation [14]. We identified certain variability criteria, including sex, professional discipline (medicine/nursing), years of experience, profile of individuals as potential adopters of innovations (according to the assessment by managers of their health area) [15,16], workload (GPs were categorised into equal thirds (low/intermediate/high) by the number of people in each GP's panel), and the practice setting (rural/urban).

We used Rogers' Diffusion of Innovation Theory [16] to describe the profiles of participants as potential adopters of innovations. According to Rogers, innovations are adopted following a S curve that plots the rate of adoption by individuals over time. Rogers classifies adopters into five categories. "Innovators" are the first

individuals to adopt an innovation, followed by "early adopters" who are the second fastest adopters, and "early majority" who will adopt the innovation significantly later than the previous groups, but before the average. "Late majority" are individuals who will adopt the innovation after the average member of the society, and "laggards" are the last to adopt the innovation. The research team was provided with information on this characteristic for only 65% of the participants, all of them lying between "innovators" and "early majority" profiles.

Three parallel focus groups of PC clinicians were organised by O + Berri, the Basque Institute for Healthcare Innovation. 7 GPs integrated one group (hence called 'Doctors' Group' (DG)). Another group was formed by 7 PC nurses (hence called 'Nurses' Group' (NG)). A mix of GPs (5) and PC nurses (4) made up the third group (hence called, 'Mixed Group' (MG)). This form of distribution aimed at exploring differences and commonalities between GPs and PC nurses' perceptions. Participating clinicians' characteristics are summarised in Table 2.

Two members of the research team participated in each group, one as facilitator and one as observer. Sessions lasted for approximately 90 minutes. A common theme exploration guide based on Graham et al.'s model [12] was used by facilitators in the three groups. All three group discussions were digitally recorded and transcribed verbatim. A thematic analysis was conducted by two members of the research team (ASO and RS) using NVivo. Thematic analysis aims to identify patterns in the data, and classify them within a limited number of themes [17]. First, the two researchers established independently a list of emerging themes based on the data, compared their results and created a final list of themes. Then, they codified each of these themes into larger categories based on concepts from Graham et al.'s model [12] (see Additional files 1, 2 and 3). As regards quotes

Table 2 Characteristics of participants in focus groups

	Group		
	Doctors	Nurses	Mixed
Sex	3 women/4 men	7 women	5 women/4 men
Practice setting	Urban: 6	Urban: 6	Urban: 7
	Rural: 1	Rural: 1	Rural: 2
Years of experience*	>25 years: 3	>25 years: 2	>25 years: 4
	10-25 years: 2	10-25 years: 1	10-25 years: 2
	<10 years: 1		
Workload*	High: 2		High: 3
	Intermediate: 3		Intermediate: 1
	Low: 1	Low: 3	Low: 1
Total	7	7	9

*Information on these variables is missing for some participants.

presented in this paper, they have been translated into English from their original Spanish version.

This study received ethical approval by the Clinical Research Ethics Committee of the Basque Country ("Comité Ético de Investigación Clínica de Euskadi"), as part of a larger project ('Development of Population Risk Stratification Applications', financed by Kronikgune Research Centre; Grant no.: Kronik11/035). Participants consented to the study by confirmatory email as well as gave oral consent for participation in the study and recording of the conversations.

Results

In our exploration of the clinicians' perceptions and experience with the PRS tool, a series of elements shaping the implementation process, and acting as its barriers and/or facilitators, naturally emerged in the discourse by participants in the focus groups. An initial finding from our approach to assessing the PRS tool's implementation process, from the clinicians' perspective, is that their views on the new tool and on the implementation process are closely interlinked and influence each other.

The implementation process appears to build up as a complex net of elements, each one of them adopting different forms for each participant, being all at once necessary to understand the implementation process as clinicians' experience it. Using Graham et al.'s theory as a guide, we present and discuss these implementation barriers and facilitators grouped into the four following categories: 1) elements related to the clinician characteristics as a potential tool adopter, 2) elements related to the clinician's perception of the practice setting, 3) elements related to the perceived characteristics of the PRS tool and, 4) elements related to the implementation strategy used by the tool's promoter, as experienced by clinicians.

Clinicians as potential adopters

The most salient element in relation to potential adopters' characteristics, and how they influence their perception of the PRS tool, and thus, the tool's implementation process, is their degree of awareness and alignment with a population health management approach. Participating clinicians showed a wide range of positions in relation to this approach, with those seeming closer to it expressing a more positive perception of the tool. In this sense, a few participants showed a solid public health perspective based on further education and previous experiences with community work. These clinicians thought of a population health management approach as an integral part of their work:

"I was working in England for four years and then returned to the Arrigorriaga unit [name of a Basque Health Services's PC unit] and when I came back, I

started identifying needs in my practice setting. The first thing I asked was: Here, what resources do we have, what society, which associations?" (DG6)

However, even professionals holding more population-health oriented positions found it somehow difficult to apply to their daily practice. Interestingly enough, they were also among those claiming more strongly for organisational changes for such an approach to become part of their everyday reality:

"...I think that the scarce time I have for individual consultations, maybe I should devote it to patients who are at a level 2 or 3, and not to patients at level 1. But if the patient is hypertensive, even if well controlled, I have to see him/her every 6 months. These are the kind of things that bother me in the daily practice. I think we could better manage our time, but the tools we have somehow force us to follow certain steps..." (DG6)

Although admitting the need to move closer to this population health management approach, a vast majority of participating clinicians however recognised working according to an individual and reactive approach, which missed acting on those not seeking care:

"...90% of our effort is for 30% of the population, maybe this is exaggerated, but the patient who does not seek care might be in very bad health. And that's my opinion, we miss delivering prevention to those outside the healthcare circuit" (DG2)

For this group of participants, the tool seemed of potential use, although they found its implementation somehow far from the possibilities of their everyday practice:

"...what should I do, what should we do?... I just don't know, I lack the tools. How can I have an impact?" (NG2)

"...I'd love to be able to meet with my diabetic patients and provide them with health education, but I don't have time, nor the tools, and I'd go as far as to say that I lack the training for it..." (DG4)

Finally, a minority group of participating clinicians, lacking a population perspective, could only envisage applying the new PRS tool in the context of the individual consultation, finding it of only limited use.

The relevance of further education and experience to be able to put a population approach in practice was also raised (as also shown in last two quotations). Participants recognised their limitations and gaps, especially in

relation to facing group and/or community interventions. Clinicians' resistance to change was also mentioned as an additional barrier to the tool's implementation, further stressing the need for training:

"Regarding group intervention, often one departs from his/her own professional resistance. And I speak from personal experience... I struggled, because facing a group of citizens... it's difficult for the professional" (NG5)

An element that seemed to act as facilitator of the PRS tool's implementation was the extent of prior knowledge and information on the tool. Previous direct experience with the tool or with the use of its results, favoured a more positive assessment, and allowed envisioning a broader range of potential applications. Specifically, nurses who had already used lists of target populations resulting from the PRS tool, found it very useful for identifying patients who could benefit from their intervention, but were not yet known/visible to them:

"I'm finding a lot of people, that is, people I didn't know myself, who were not coming in for appointments and I didn't even know how they looked like and, nevertheless..." (NG4)

Clinicians' professional discipline also seemed to influence their perception of the tool, and hence their experience with its implementation process. In this sense, participating nurses, a discipline traditionally further geared to action than doctors, seemed to assess the tool at the very "feet-on-the-ground" intervention level, establishing strong links between the tool and the interventions it could be used for. In addition, their interest seemed to focus on community and group interventions:

"...I would focus more on people who have already been diagnosed, sending them reminders about healthy habits every three months..." (NG2)

In addition, it was observed that some clinicians showed a special concern about evidence-based practice, questioning about the evidence on the tool's effectiveness.

Practice settings where the tool is to be implemented

A large amount of comments by the participating clinicians related to barriers and facilitators in their practice settings. Regarding practice-setting barriers, on the one hand, clinicians referred to an overwhelming individual clinical demand in their daily practice, which prevented them from developing a more proactive role and thus from getting closer to a population health management approach. Patients' dependency on the healthcare system and resistance to change, within a culture

where responsibility for health is seen to rely mainly on healthcare professionals, seemed to further prevent from overcoming this barrier:

"...Not every problem people may have is to be solved by the [healthcare] system. However, we have created a society where problems must be solved by the [healthcare] system. And there are things that need to be solved by the individual..." (NG1)

A certain lack of coherence between the evaluation tools used by managers to assess clinicians' practice performance, and the premises underlying a population health management approach, was also experienced as a barrier to the implementation process. As expressed by participants, assessment tools in place were oriented towards individual activities, and not towards results on population health:

"...I think that this needs to be clearly set out: [patients] whose condition is well under control don't really need all the follow-up appointments the system requires us to perform" (DG6)

Finally a change-saturated practice context seemed to also act as a barrier to the implementation of the new tool PRS in clinicians' busy practices. The numerous management-driven changes being simultaneously implemented in their practice settings at the time the PRS tool was introduced [3] (although often in line with the participants' professional views and values), seemed to compete for clinicians' time and effort:

"...and so I think that we are in maelstrom of changes at the moment, changes that clearly needed to be implemented, but (in the midst of them) nobody gives us any clear guidance on how to act, or where to start, ..." (MG6)

Participating clinicians also identified elements that, if implemented, would facilitate the new tool's implementation in their everyday clinical practice. Among these facilitators, clinicians manifested the need for additional organisational changes. On the one hand, as expressed by participants, time limitations could be overcome by reconsidering current assignments and realigning them in coherence with a population health management approach (ie. reducing the time traditionally allocated to certain patients/groups currently receiving very little-impact interventions, in order to increase efforts with patients/groups not yet visible/identified but who might further benefit from clinicians' attention). The development of new professional roles (already ongoing at the time), in line with further changes in work flows among

professionals, and more teamwork, were other organisational changes suggested by participants:

"I wonder: how can the (Population Risk) Stratification be of use for Primary Care? ...First of all, which sort of Primary Care are we talking about? Are we talking about the one currently in place or another sort of it? Is this (PRS) strategy willing to assign everyone, doctors, nurses, new roles? Or not? Shall we be talking about the Primary Care as we know it nowadays, nothing will change, everything will stay just the same as we have seen it since the 80s. Of what use is this to us? So far, of no use, just a new icon to be shown on the screen. Is the system willing to further develop (professional) roles?" (DG3)

Participating clinicians also pointed at the coordination between healthcare and social care institutions and community organisations (e.g. patients' associations, community cultural and sport centres, etc.) as a necessary element for promoting the development and adoption of community/population approaches, seen as linked to a more valuable use of the PRS tool.

The perception of the tool's characteristics

Participating clinicians identified several elements related to the reliability, desirability and applicability of the stratification tool, which acted as implementation barriers and/or facilitators, depending on the case. So, on the one hand, they questioned the reliability of the tool, mainly as regards the quality of the diagnosis data it builds upon:

"... it's based on the ICDs [International Classification of Diseases], but codification is very badly done..." (DG1)

Its US origin was another issue pointed out when questioning the reliability of the tool, the US healthcare system seen as radically different from the public Basque healthcare system:

"... Why are we always to be compared to the Americans? What does our healthcare reality have to do with the American one?... What does a person, with free access to healthcare here, have to with an American,..." (NG1)

Further, the lack of social data in the database the tool relied upon was also mentioned by participating clinicians. They referred to social factors as key determinants of health needs and thus, essential data that the tool needs to contemplate in order to be useful. Particularly nurses strongly stood up at this point:

"But, which criteria are now being used to identify them (at-risk patients)? Those (patients) not causing

any trouble? Those (patients) suffering from one disease? It could be that he/she suffers from 5 diseases but is in great form or getting large support from the private sector... Their (health issues) will not show up in the same way as for other people living in different (social) conditions... I cannot look at them (patients in different social circumstances) the same way, I just don't look at them the same way" (NG7)

In addition, clinicians having already been given patients' lists produced by the tool had been able to identify several errors in the allocation of patients, which eroded their trust.

Participating professionals also talked about several aspects that seemed to limit the desirability of the tool's implementation in their everyday practice. Firstly, some participants found it difficult to see the advantages of this new tool when compared to other pre-existing tools for identifying target populations. Secondly, in terms of equity in healthcare provision, some clinicians admitted serious worries related to the risks associated to the use of the tool for establishing priorities amongst patients. Thirdly, professionals raised questions regarding the amount and quality of the available evidence concerning stratification-based interventions.

Finally, participating clinicians pointed out several aspects the tool should incorporate in order to make it of easier application to their daily practice, and which could act as implementation facilitators. In this sense, professionals in the groups asked for:

- more independent management and exploitation of the information by every clinician (especially requested by GPs),
- further information on patients outside recommended clinical levels and/or those off clinicians' radar (i.e. those not seeking care),
- regularly updated information on patients,
- incorporating social data and information on mental health conditions,
- a more user-friendly display as for locating patients (at the time it could only be done by patient's identification code), as well as for alerting clinicians on special issues (patients with values outside recommended clinical levels, with pending interventions...):

"The only information we have on that stratified patient is an orange icon [in the electronic health record], but, when you open his/her health record, you do not see where you have to intervene, which stratification parameters require intervention, or whether the patients' values are well-controlled... you have to enter into each medical diagnosis, conduct a data search... it's not visual, quick or blunt..." (MG5)

The promoter's implementation strategy

The implementation strategy followed by the promoter of a new tool (or innovation), is a critical element in an implementation process [12]. So, the strategy followed by the Basque Health Service's general management to incorporate the new PRS tool into clinicians' everyday practice received many comments from the clinicians participating in the focus groups. Three major issues/elements were pointed out (implementation process, information and confidence). All three of them were mutually interrelated and, at the same time, origin and effect of each other. For the purpose of this paper, we shall however present them linearly.

To start with, participating clinicians talked about the process of development and introduction of the new PRS tool in their daily practice, which they considered should have been based on a prior assessment of their practice needs. As they stated it, they were only asked to contribute once the tool was already to be applied. An earlier clinicians' involvement would have necessarily eased their acceptance of the tool and hence, the tool's implementation process:

"... what really strikes me about this meeting here today is how someone who has previously designed something, now comes and asks me about the purposes/utilities of it, the way to use it... whoever designed it must have thought about how it should be used and what for... honestly, this really strikes me..." (NG1)

When reflecting on how the new tool could be better disseminated across the system, some participants suggested appointing a contact person from the team responsible for the development-implementation of the tool, who would be available for answering clinicians' questions and concerns.

Participants largely and soundly talked about the information they were provided with. In this sense, participating clinicians clearly showed the relevant role the information seemed to play on the process of accepting and integrating the new tool in their everyday practices. This seemed even more relevant considering that, firstly, target-population interventions emerging from the use of the tool were linked to professional performance assessment. And moreover, results from the PRS tool appeared in the patient's electronic health record used by clinicians for their daily practice:

"I thought it was only at my (Primary Care) centre that information had not been received, but I now understand that this (lack of information) was happening all over. We did not have any meeting. This means that, right from the outset, I do not feel comfortable with it, because, as I was just sent a

bounced email on the stratified individuals, I don't know what it's all about; it's as if this would not be of my business since I was never invited to get involved" (DG7)

The facilitating role of the information on the assessment of the PRS tool could also be noticed over the course of the group discussions. In fact, clinicians showing very limited initial knowledge on the tool and its usefulness, as discussions progressed and knowledge was shared, gradually started to envisage a wider range of potential uses.

Finally, participants in the groups extensively elaborated on the level of confidence on the promoter of the tool-implementation (ie. the general managerial level), which also depended on both, the process followed for the tool's development and introduction in the practice setting, as well as the information on the tool and its objectives and the way it had been provided. Clinicians identified several elements related to building up confidence on tool-promoters:

- The perceived clarity on the objectives sought by the organisation when introducing changes in clinicians' contexts of practice. In this sense, linking the implementation of the new tool to professional performance indicators proved not to be an adequate strategy when seeking to increase acceptance. Clinicians would have more easily accepted the tool should they had been provided information in regards to its potential uses when aiming at improving their clinical practice and achieving better population health outcomes. Nurses showed to be especially firm at demanding further information on the goals of the stratification strategy, as well as clearer directions regarding their tasks in relation to the use of the tool.
- The perceived distance between clinicians and managers, both in relation to managers' initiatives (not) reaching the frontline level, as well as to the frontline-level work (not) being sufficiently visible and known to managers.
- The level of evidence on the benefits associated to innovations introduced by managers, with clinicians asking for initiatives to be previously tested and benefits clearly shown.
- The gradual introduction of innovations, as to have them tested in different contexts and realities within the healthcare system, and to be able to adequately tackle any potential difficulties arising in the implementation process:

"...before when any new activity was to be introduced... [examples], it was first pilot-tested in rural areas, urban areas and other, then difficulties

that emerged were monitored and gradually tackled. By the time it was spread out to other centres, problems were still being identified. Nowadays, an innovation is pilot-tested in Bilbao [urban area] where not one single issue may come up, but practice in Bilbao is different from practice in "Interior" [name of a rural health area], totally different. It (the innovation) is then introduced in "Interior" health area and it just doesn't work..." (MG6)

Discussion

Graham et al.'s Knowledge Translation Theory [12,13] has proved to be a suitable framework to explain the implementation process of a new PRS tool in daily PC practice in the Basque Health Service. Our findings also point at the reciprocal relationship between the potential adopters' perceptions of the implementation process and their perceptions of the new tool (or innovation).

Several characteristics of the potential adopters influence the tool's implementation process. Clinicians' values, beliefs and attitudes regarding population health approaches seemed to be among them. So, clinicians showing a stronger population perspective seemed to understand the potential benefits of the tool more easily, and be more favourable to its implementation. Most participating clinicians however saw the need to move closer to a population health management approach. But they recognised that their current practice was geared towards patient-sought individual consultations. In line with these findings, it could be of interest for the success of future implementations of population health management tools, to previously work on bridging the gap between the values underlying the tool and the actual daily clinical practice of their potential adopters. This is likely to require organisational adaptations and further training of staff. Supporting clinical leaders acting proactively and with a population focus could also be of help in signing the way to their colleagues.

Elements related to the practice setting seemed to be of particular relevance in the implementation process. Amongst them, workload, work assignment, roles, and professional performance assessment strategies in place seemed particularly strong in preventing clinicians from adopting more proactive attitudes as well as from undertaking further health promotion activities. It seems then necessary to undertake additional organisational changes and innovations, accompanying the tool's implementation strategy, that facilitate and provide the necessary tools for clinicians to develop a population health management approach. This finding corresponds to the view of other authors such as Lewis [3], about the need to implement risk prediction tools as part of a wider strategy, as these tools in isolation have no impact on health,

rather their effectiveness depends on the interventions performed with the identified patients.

Resistance to change towards a population approach by patients (particularly those for whom services would be reduced) was noted as an additional obstacle. In this sense, it appears that a good communication strategy towards the population and supporting chronic patients develop self-management skills could contribute to adequately overcoming this barrier [18].

The implementation of the stratification tool also depends to a great extent on the way the tool itself is perceived by its potential adopters. Specifically, the clinicians referred to attributes of the tool in relation to its reliability, to the evidence that supports its use, to issues related to the variables included, to its format and ease of use, as well as to the ethical implications of using its results (specifically in relation to equity in the provision of healthcare on the basis of stratification criteria). Other authors have also considered the equity risks linked to the use of predictive models for targeting multimorbid care management interventions [19]. Among the criteria, which seem to generate the most concerns about the reliability of the tool are doubts about the coding of the diagnoses on which the estimates of the model are based, as well as the fact that information of a social nature is not considered. It should, however, be noted that the introduction of this social information was already planned by the developers of the tool, although it was not incorporated in the first version available at the time of the focus groups. Mention was also made (at least among the physicians) to a desire for more independence for each PC team to manage and exploit the information from the stratification tool, as well as a need for the data to be kept up-to-date. These views are in line with those of clinicians in the German study, who also expressed concerns about a time lag between the analysis with the predictive model and the intervention with patients [8]. With respect to complaints about variables, format and accessibility, the tool introduced in Wales seemed to have advanced further, likely due to greater involvement of frontline clinicians in its development [7].

With respect to the aforementioned barriers and facilitators and the elements of the implementation strategy mentioned by the clinicians, it is possible to make a series of recommendations for future implementation strategies for PRS tools. In general terms, these recommendations would aim to bring the tool and its implementation closer to the needs and values of its final users, since, as asserted by Logan et al., the closer to the final user, the more likely that the implementation strategies will be effective [13]. To this end, on the one hand, it seems crucial that clinicians get involved from the early phases of design and implementation of this type of tools, so that they are well suited to their needs and

practice settings, before they are scaled up to the entire healthcare system and incorporated into their daily information systems. Moreover, direct experience with the tool seems to improve its assessment by practitioners, as is also shown in other studies on the implementation of risk stratification tools [20]. This would help to foster trust in the tool and in the objectives searched by its promoter. For this, the implementation strategy through pilot site practices used in Wales could be a good model [7], which would also respond to the demands from some clinicians for evidence concerning the positive results of using the stratification tool before its scaling up.

It also seems key to strengthen efforts in communication and provision of information about the tool and its objectives to frontline clinicians (the final users of the tool), especially when the tool requires a change in their usual practice, in this case, from an individual towards a population health management approach. The demand for clarity about the pursued objectives seems to be particularly relevant for nurses. Moreover, this should be a two-way communication, allowing final users to share their impressions and requests in relation to the use of the new tool.

Finally, the implementation strategy should be better aligned with the tool's goal of promoting proactivity and autonomy by the clinician. Hence, at least in a first phase of implementation of the tool, rather than uses linked to activity indicators common to the entire organisation and established by managers, strategies that allow greater self-management and adaptation to the local context and interests of each PC team would be more likely to be successful (especially among physicians). Such strategies would be supported by a reorientation of the criteria used for the evaluation of PC practice performance towards measuring the impact on population health.

Lastly, among the limitations of this study we should note weaknesses in the method chosen for selecting the participants in the focus groups, especially with respect to their profiles as adopters of innovations [15,16]. On the one hand, a common tool was not used to classify participants according to their innovation profile and ensure comparability, rather the management of each PC health area characterised their clinicians. On the other hand, it was the managers themselves who decided which clinicians would participate in the focus groups, which could have brought a selection bias towards clinicians who were relatively advanced adopters (from "innovators" to "early majority"). Due to these factors, the results reported here might not represent the realities of clinicians less inclined towards innovation, who also form part of the health system under study. However, we believe that this potential bias is limited because participants in the focus groups showed a wide range of profiles and perceptions towards population management, the stratification tool and its implementation process.

Conclusions

This study confirms that implementing a PRS tool in PC's everyday practice is a culturally and organisationally complex process, built upon the intersection of a series of interrelated elements. These elements relate to the characteristics of the potential adopters, their perceptions of their practice settings, their perceptions of the characteristics of the new tool, and their experience with the implementation strategy used by the tool's promoter.

Several lessons on the implementation of a new PRS tool in clinicians' daily practice can be drawn from the results of our study. Firstly, in a PC context where an individual approach prevails in clinicians' everyday practice, the implementation of a population health management tool needs to be framed within a wider strategy promoting a re-orientation towards a population approach. This might require additional organisational changes, such as those identified by the study participating clinicians (clinical practice priorities and assessment tools reoriented, time redistribution, role reassignment, further education and training in population health management and community interventions, increased coordination with social services and community organisations etc.). However, account should also be taken of the risks associated with introducing simultaneous changes in clinicians' busy daily practices. In this sense, the implementation of a PRS tool within a broader system-level reform strategy would require a substantial effort in planning and communication with frontline clinicians, aimed at avoiding a feeling of change-saturation.

A major issue emerging from the results of our study is the relevance of approaching the new to-be-implemented PRS tool to clinicians' values, needs and concerns. On this issue, the role of an adequate implementation strategy does not risk being overemphasised. This strategy should not only guarantee smooth communication channels between clinicians and managers, but it should also ensure sensitivity and flexibility to the particular characteristics and circumstances of the diverse practice settings where the tool is to be implemented. This would necessarily mean involving frontline clinicians, as adopters-to-be, right from the very early phases of tool conceptualisation, design and implementation, and allowing them to test and adapt the tool to their own practice settings.

Additional files

Additional file 1: Doctors' group node tree [in Spanish]. Node tree resulting from thematic analysis of the Doctors' group transcribed discussions using NVivo, excel file.

Additional file 2: Mixed group node tree [in Spanish]. Node tree resulting from thematic analysis of the Mixed group transcribed discussions using NVivo, excel file.

Additional file 3: Nurses' group node tree [in Spanish]. Node tree resulting from thematic analysis of the Nurses' group transcribed discussions using NVivo, excel file.

Abbreviations

PRS: Population risk stratification; PC: Primary care; GP: General practitioners; DG: Doctors' group; NG: Nurses' group; MG: Mixed group.

Competing interests

The authors have no financial competing interests to declare.

RNS and JFO declare what might be considered non-financial competing interests. JFO was the principal researcher responsible for the project of population risk stratification using the Adjusted Clinical Groups Predictive Model for the public Basque Health Service (Osakidetza). RNS is the Director of O + Berri, main funding agency of the stratification project. Nevertheless, these authors' contribution to this work was limited to its conception, design and coordination, as well as technical advice concerning the tool. Hence, their interests have not influenced the results presented here.

Authors' contributions

RSA facilitated one of the focus groups, co-conducted analysis and participated in the drafting of this paper. RSA (Degree in Business Studies) is Senior Researcher at O + Berri. ASO designed the study, provided methodological support, co-conducted analysis and participated in the drafting of this paper. ASO (RN, BScHs in Nursing, MSc, PhD Cand) works as clinical nurse at an acute care hospital of the public Basque Health Service, Osakidetza. JFO participated in the design of the study, the organisation of the focus groups, and the drafting of the background section of this paper. JFO is paediatrician, and Head of the PC centre of Astrabudua (belonging to the public Basque Health Service, Osakidetza). MPG contributed to the analysis and presentation of results. MPG (PhD in Community Health) is Associate Professor at the Faculty of Nursing Sciences at Université Laval and researcher at the Research Centre of the CHU de Québec. RNS conceived the study and participated in its design and coordination. RNS (Degree in Economics and Business Administration, MSc in Health Economics) is Director of O + Berri. All authors participated in critically reviewing the manuscript and approving its final version.

Acknowledgements

We are grateful to the 23 participating professionals for their active and enriching contribution through open discussions in the groups. We also would like to thank Emilio Herrera and his team, as well as Maider Mateos, for their support at organising and facilitating the group meetings. We also thank Kronikgune research centre ("Asociación Centro de Excelencia Internacional en Investigación sobre Cronicidad") for funding of the project "Desarrollo de aplicaciones de la estratificación poblacional" (Development of Population Risk Stratification Applications), to which this study belongs (Grant no.: Kronik11/035).

Author details

¹O + Berri, Basque Institute for Healthcare Innovation, Torre del BEC, Ronda de Azkue, 1, 48902 Barakaldo, Bizkaia, Spain. ²Osakidetza, Álava-Txagorritxu University Hospital, Jose Atxotegi s/n, 01009 Vitoria, Spain. ³Osakidetza, Astrabudua Health Center, Mezo 35, 48950 Erandio, Spain. ⁴Faculty of Nursing, Université Laval, 2325 rue de l'Université, Québec, Canada.

Received: 22 October 2013 Accepted: 2 June 2014

Published: 8 September 2014

References

1. Thorlby R: Reclaiming a population health perspective: Future challenges for primary care. *Nuffield Trust* 2013, http://www.nuffieldtrust.org.uk/sites/files/nuffield/publication/130425_reclaiming-a-population-health-perspective.pdf.
2. Nuño Solinís R, Contel Segura JC, Orueta Mendia JF, García Alvarez A, Lewis G: Development and implementation of risk stratification tools: Practical tools to identify patients with complex needs. *O+Berri Working Paper*, 1/2013 [http://www.researchgate.net/publication/257921805_Risk_stratification_tools?ev=prf_pub]
3. Nuño R, Piñera K: Strategy for tackling the challenge of chronicity. *Health Policy Monitor* 2010, <http://www.hpm.org/es/a16/1.pdf>.
4. Nuño-Solinís R, Orueta JF, Mateos M: An answer to chronicity in the Basque Country: primary care-based population health management. *J Ambul Care Manage*. 2012, **35**:167–73.

5. Johns Hopkins University, School of Public Health: **The Johns Hopkins University ACG Case-Mix System**. http://www.acg.jhsph.org/index.php?option=com_content&view=article&id=46&Itemid=61.
6. Orueta JF, Mateos Del Pino M, Barrio Beraza I, Nuño Solinís R, Cuadrado Zubizarreta M, Sola Sarabia C: **Estratificación de la población en el País Vasco: resultados en el primer año de implantación**. *Aten Primaria* 2013, **45**:54–60.
7. Kingston M: **Initial Uses of the PRISM Risk Stratification Tool in CCM Demonstrator Sites: A qualitative study**. **Chronic Conditions Management Demonstrators: Evaluation Report**. NHS Wales. 2010 [<http://www.wales.nhs.uk/sitesplus/documents/829/CCM%20Demonstrator%20PRISM%20Report%20Aug10.pdf>]
8. Freund T, Wensing M, Geissler S, Peters-Klimm F, Mahler C, Boyd CM, Szecsenyi J: **Primary care physicians' experiences with case finding for practice-based care management**. *Am J Manag Care* 2012, **18**:e155–61.
9. Sicras-Mainar A, Prados-Torres A, Navarro-Artieda R: **Opinión de los médicos de atención primaria sobre el uso de un sistema de ajuste de riesgos: los adjusted clinical groups**. *Rev Peru Med Exp Salud Publica* 2013, **30**(2):345–7.
10. Nuño Solinís R, Contel Segura JC, Orueta Mendia J, Alvarez A: **Guía para el desarrollo e implementación de herramientas de estratificación de riesgos**. In *Monografía IEMAC 1.0*. http://www.opimec.org/media/files/gua_iemac.pdf.
11. Lewis G, Curry N, Bardsley M: **Choosing a Predictive Risk Model: A Guide for Commissioners in England**. In *Nuffield Trust*. November 2011. [http://www.nuffieldtrust.org.uk/sites/files/nuffield/publication/choosing_predictive_risk_model_guide_for_commissioners_nov11.pdf]
12. Graham ID, Logan J: **Innovations in knowledge transfer and continuity of care**. *Can J Nurs Res* 2004, **36**:89–103.
13. Logan J, Graham ID: **Toward a comprehensive interdisciplinary model of health care research use**. *Science Communication* 1998, **20**:227–246.
14. Rycroft-Malone J, Kitson A, Harvey G, McCormack B, Seers K, Titchen A, Estabrooks C: **Ingredients for change: revisiting a conceptual framework**. *Qual Saf Health Care* 2002, **11**:174–80.
15. MacDermid JC, Graham ID: **Knowledge translation: putting the "practice" in evidence-based practice**. *Hand Clin* 2009, **25**:125–43.
16. Rogers EM: *Diffusion of Innovations*. 5th edition. New York: Free Press; 2003.
17. Braun V, Clarke V: **Using thematic analysis in psychology**. *Qualitative Research in Psychology* 2006, **3**:77–101.
18. Coulter A, Ellins J: **Effectiveness of strategies for informing, educating, and involving patients**. *BMJ* 2007, **335**(7609):24–27.
19. Shadmi E, Freund T: **Targeting patients for multimorbidity care management interventions: the case for equity in high-risk patient identification**. *Int J Equity Health* 2013, **12**(1):70.
20. Wu RR, Orlando LA, Himmel TL, Buchanan AH, Powell KP, Hauser ER, Agbaje AB, Henrich VC, Ginsburg GS: **Patient and primary care provider experience using a family health history collection, risk stratification, and clinical decision support tool: a type 2 hybrid controlled implementation-effectiveness trial**. *BMC Fam Pract* 2013, **14**(1):111.

doi:10.1186/1471-2296-15-150

Cite this article as: Arce et al.: A qualitative study on clinicians' perceptions about the implementation of a population risk stratification tool in primary care practice of the Basque Health Service. *BMC Family Practice* 2014 **15**:150.

Submit your next manuscript to BioMed Central and take full advantage of:

- Convenient online submission
- Thorough peer review
- No space constraints or color figure charges
- Immediate publication on acceptance
- Inclusion in PubMed, CAS, Scopus and Google Scholar
- Research which is freely available for redistribution

Submit your manuscript at
www.biomedcentral.com/submit



Referencias bibliográficas: (182,106,157,14,102,107,183,122,184–193)

3.4 OBJETIVO 4: ESTABLECER LA VALIDEZ DE UN NUEVO SISTEMA DE CLASIFICACIÓN DE PACIENTES Y SU APLICABILIDAD COMO INSTRUMENTO DE ESTRATIFICACIÓN POBLACIONAL.

3.4.1 Introducción .

Como se ha descrito en las anteriores páginas, el estudio de la multimorbilidad es un tema de creciente interés para clínicos, gestores de sistemas sanitarios y economistas de la salud (1). A ello contribuyen diversos motivos. El progresivo aumento de su prevalencia hace que sea considerada actualmente una auténtica epidemia a nivel mundial. La multimorbilidad disminuye la autonomía funcional y calidad de vida de las personas que la presentan (32); por ello, representa una carga importante no sólo para tales personas, sino también para las familias que les cuidan. Además, las organizaciones sanitarias fueron diseñadas para solucionar episodios agudos de enfermedad y tienen dificultad para atender a estos pacientes (14), lo cual redundará en la obtención de peores resultados en la atención a estas poblaciones (59) y en el incremento de sus costes (70,71). Debido a ello se han planteado nuevos modelos asistenciales que permiten mejorar la calidad de la atención sanitaria a las personas con enfermedades crónicas y pluripatologías, cuya eficacia ha sido comprobada (75,76).

Sin embargo, no todas las personas tienen la misma carga de morbilidad ni resulta razonable ofrecerles las mismas intervenciones. La estratificación poblacional pretende identificar subgrupos de pacientes que presentan necesidades similares de atención sanitaria, con el fin de implantar actuaciones específicas que resulten apropiadas para cada uno de estos perfiles. Los sistemas de ajuste de riesgo (*case-mix*) fueron desarrollados originariamente en Estados Unidos para facilitar una financiación más equitativa a las organizaciones sanitarias (78,79). Resultan ser instrumentos muy potentes desde el punto de vista estadístico y versátiles en sus aplicaciones, lo permite su empleo

para identificar de manera anticipada a las personas que requerirán recursos sanitarios especialmente costosos o presentan un mayor riesgo de ser hospitalizados.

Un factor a tener en cuenta al implantar los sistemas americanos de ajuste de riesgo en nuestro ámbito es su sofisticación. Manejan mucha información y emplean modelos estadísticos complejos, que pueden plantear dificultades para ser comprendidos e interpretados correctamente por los clínicos y gestores. Además, las predicciones que ofrecen sobre el nivel de riesgo de determinados pacientes pueden contradecir percepciones intuitivas de los profesionales sanitarios. Por todo ello, se presentan dudas sobre la aceptación de estos sistemas por los clínicos y su correcta aplicación en nuestras organizaciones.

En consecuencia, en este trabajo se propone una alternativa diferente para la estratificación poblacional. La creación de un nuevo instrumento, cuya metodología para la segmentar a la población en niveles de necesidad asistencial resulte muy fácil de comprender. Se pretende que cuente con un diseño simple, que resulte transparente en todas sus fases de clasificación y que ofrezca unas predicciones que puedan interpretarse sin esfuerzo. Sin embargo, no se trata de ofrecer un simple listado de problemas de salud sin ninguna validez estadística; en nuestro medio, con cierta frecuencia, las organizaciones sanitarias han aceptado escalas y sistemas similares, adoptados simplemente por consenso de un grupo de trabajo, basados en la experiencia de sus miembros y su intuición, pero cuya validez estadística no ha sido comprobada. El nuevo instrumento debe contar con una capacidad predictiva suficiente, si bien es plausible que resulte inferior a la de los *case-mix* americanos, pues sólo empleará unas pocas variables explicativas de obtención sencilla. Esta facilidad de uso puede compensar una discreta disminución en la capacidad predictiva; si se consigue que resulte atractivo para los profesionales sanitarios, previsiblemente se utilizará de un modo adecuado y permitirá poner en marcha programas de intervención basados en sus predicciones.

3.4.2 Métodos

3.4.2.1 Evaluación Ética

El protocolo de este estudio fue aprobado por el Comité Ético de Investigación Clínica de Euskadi (CEIC-E). Código: PI2015128.

3.4.2.2 Descripción población de estudio

Este es un estudio transversal. La población de estudio estuvo formada por las personas que dispusieron de aseguramiento sanitario público en el País Vasco el día 1 de septiembre de 2008. El periodo de estudio corresponde a dos intervalos consecutivos de 12 meses. Los datos del primer año (de 1 de septiembre de 2007 a 31 de agosto de 2008) se emplearon para elaborar las variables explicativas y los del segundo año (de 1 de septiembre de 2008 a 31 de agosto 2009) las variables respuesta. La base de datos utilizada en este estudio es la que ya fue empleada anteriormente para analizar la validez de modelos basados en ACGs, CRGs y DCGs (174) para predecir el consumo de recursos en nuestro medio y de predicción de hospitalizaciones mediante ACGs (141).

Dado que nuestro método de estratificación está basado en la presencia de enfermedades crónicas y su fin principal es identificar a las personas con mayores necesidades de atención sanitaria se decidió excluir del estudio a la población pediátrica (pacientes menores de 14 años de edad).

Por otra parte, se aceptaron personas que no completaron los 24 meses de seguimiento, con los siguientes criterios:

- En el primer año, las personas que sólo dispusieron de cobertura sanitaria por Osakidetza durante un plazo de tiempo muy corto pudieron no haber tenido tiempo de consultar por todos sus problemas de salud y, en consecuencia, su clasificación resultar incorrecta. Sin embargo, se decidió que un periodo mínimo de 6 meses podía ser suficiente para que los sistemas de información sanitaria identificaran dichos los problemas de salud. En consecuencia, se aceptaron todas las personas que, durante al menos 6 meses, tuvieron asignado un médico de Osakidetza, independientemente de que realizaran o no algún contacto con los sistemas sanitarios (n =1.956.448).
- Los últimos meses de la vida de las personas concentran una parte sustancial de su consumo de recursos sanitarios. La exclusión de esta fase alteraría los resultados y por tanto, se incluyeron las personas que no completaron el segundo año de estudio debido a fallecimiento (n = 18.548) pero se rechazaron las que lo hicieron por traslado u otras causas (n = 9.634).

Por tanto, la población de estudio estuvo constituida por 1.946.884 personas, de las que, el 51,2% son mujeres y un 21,5% mayores de 65 años. Una distribución en grupos de edad y sexo puede verse en la Tabla 6.

Tabla 6. Distribución de la población en grupos de edad y sexo, promedios de diagnósticos y porcentajes de pacientes con algún diagnóstico y patología crónica

Grupos de Edad	Varones		Mujeres		Promedio Diagnósticos únicos por paciente	% Pacientes con algún diagnóstico	% Pacientes con una o más patologías crónicas (GRECs)
	N (%)	N (%)	N (%)	N (%)			
14-24	100.268 (5,15%)	95.660 (4,91%)	1,58	52,06%	14,26%		
25-34	177.693 (9,13%)	169.978 (8,73%)	1,73	51,97%	16,38%		
35-44	193.226 (9,92%)	186.397 (9,57%)	1,93	52,77%	21,25%		
45-54	164.043 (8,43%)	165.411 (8,50%)	2,55	58,28%	33,35%		
55-64	135.520 (6,96%)	138.340 (7,11%)	4,29	73,33%	51,16%		
65-74	94.628 (4,86%)	106.810 (5,49%)	6,54	84,62%	64,81%		
75-84	66.904 (3,44%)	94.873 (4,87%)	7,88	86,48%	70,11%		
85+	16.877 (0,87%)	40.256 (2,07%)	6,54	72,44%	57,47%		
Total	949.159 (48,75%)	997.725 (51,25%)	3,00	63,01%	35,56%		

3.4.2.3 Fuentes de información

Se extrajeron datos de las fuentes de información disponibles: historias clínicas informatizadas de atención primaria, conjunto mínimo básico de datos de informes de alta de hospital (CMBD), archivos con registros informatizados de hospital de día y de citación en urgencias y consultas de asistencia especializada. Corresponden a:

- Datos demográficos: edad y sexo.
- Datos clínicos: códigos CIE-9-MC de los diagnósticos de cada contacto con atención primaria, ingresos en hospital y hospital de día. La codificación en atención especializada se realiza por técnicos en documentación clínica, pero en primaria son los propios médicos quienes deben efectuar esta tarea cuando establecen o modifican un diagnóstico. Una descripción más detallada de este proceso puede encontrarse en otra publicación (115).
- Utilización de recursos sanitarios y coste de la atención: Respecto al coste, éste sólo pudo obtenerse directamente para las prescripciones de atención primaria registradas en las historias clínicas informatizadas. En los otros casos (visitas a urgencias de hospital, consultas externas de atención especializada, médicos y enfermeras de atención primaria; analíticas y exploraciones radiológicas solicitadas en atención primaria; algunos procedimientos como diálisis, radioterapia o quimioterapia realizados en hospital de día) se multiplicó el número de servicios a cada paciente por su coste estandarizado. Los costes de hospitalizaciones y procedimientos de cirugía mayor ambulatoria se calcularon en función de los pesos de sus correspondientes GRDs. De la estimación de coste quedaron excluidos algunos servicios de los que no fue posible obtener información: salud mental (tanto ingresos como consultas externas), servicios de hospitalización a domicilio y hospital de día (excepto los

procedimientos anteriormente citados), rehabilitación ambulatoria, transporte sanitario, prótesis y otros equipos entregados a pacientes en domicilio.

De este modo, se obtuvieron un total de 19.352.975 diagnósticos procedentes de atención primaria y especializada, que corresponde a 12.300 códigos CIE-9-MC distintos.

3.4.2.4 Fases en la clasificación de los pacientes y elaboración del algoritmo agrupador de enfermedades crónicas.

3.4.2.4.1 Identificación de las Patologías Crónicas.

El sistema FINGER es un desarrollo propio, cuya elaboración se apoyó en instrumentos de difusión libre, creados por la *Agency for Healthcare Research and Quality (AHRQ)* americana. Dicha agencia, a través de del proyecto *Healthcare Cost and Utilization Project (HCUP)*, ha generado un conjunto de instrumentos para facilitar la investigación en un amplio rango de campos relacionados con la gestión y planificación sanitaria. Entre estos instrumentos se encuentran *Chronic Condition Indicator (CCI)*(194) y *Clinical Classifications Software (CCS)* (195). Ambos fueron diseñados para permitir que los datos clínicos (habitualmente clasificados mediante CIE-9-MC) puedan ser presentados de un modo más fácil de interpretar. CCI identifica de manera rápida la presencia de diagnósticos crónicos y CCS colapsa los códigos CIE-9-MC en un número manejable de categorías para realizar estadísticas descriptivas de los problemas de salud en una población.

Así pues, con el fin de seleccionar enfermedades crónicas en este estudio se empleó el *Chronic Condition Indicator (CCI)*. Según esta clasificación, son crónicos los problemas de salud cuya duración

prevista es igual o superior a un periodo de 12 meses, durante el cual se cumple al menos una de estas condiciones: el paciente presenta limitaciones (para su vida independiente o interacción social) o requiere cuidados sanitarios continuados.

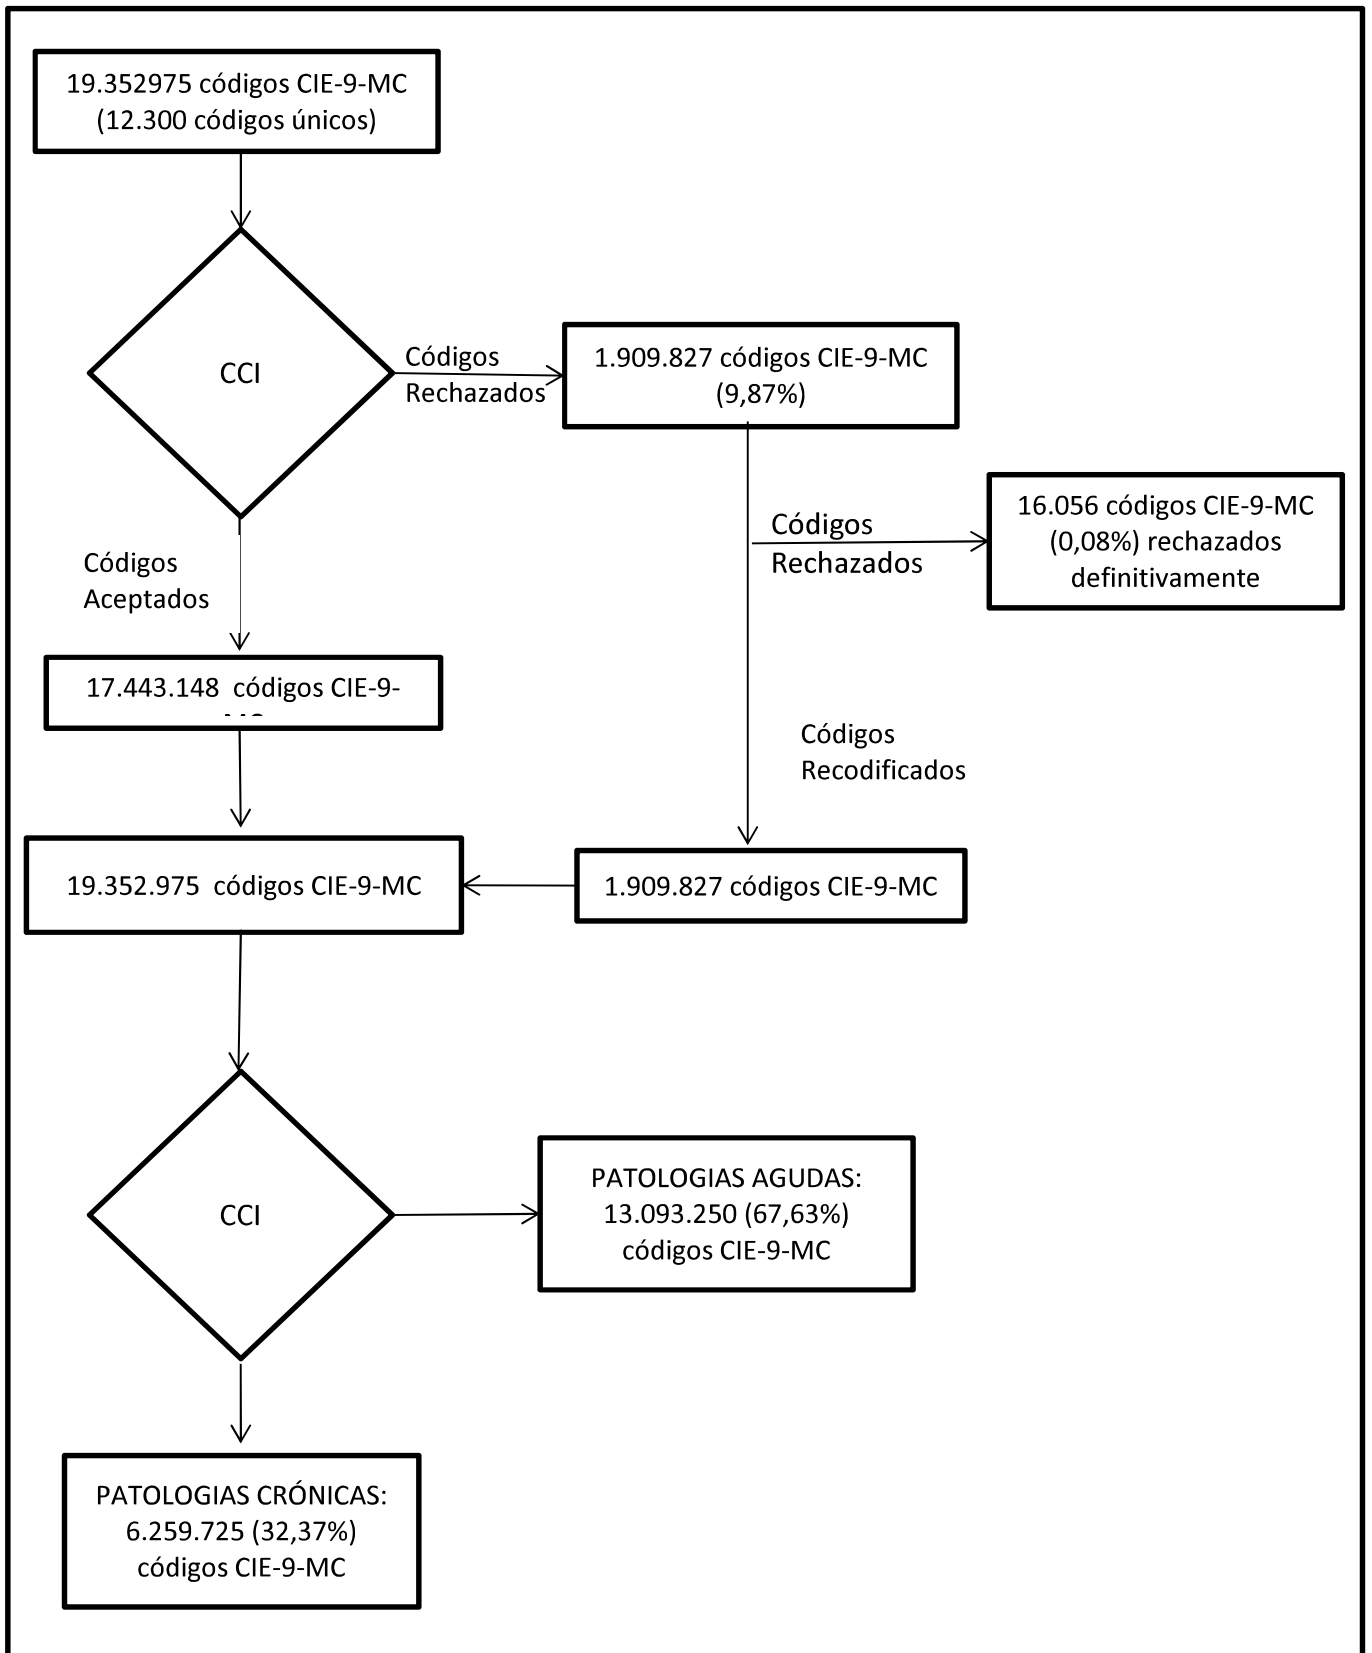
El algoritmo CCI categoriza así todos los códigos CIE-9-MC en dos grupos: patologías crónicas y no crónicas. Un requerimiento de este sistema es que las enfermedades deben codificarse en CIE-9-MC empleando 5 dígitos y, en muchos casos, rechaza los códigos que contienen un nivel de precisión menor (esto es, 3 ó 4 dígitos).

Sin embargo, en las organizaciones sanitarias en nuestro país y especialmente en atención primaria, resulta muy común el empleo de códigos con menos de 5 dígitos. Así, en la base de datos de este estudio, 1.909.827 (9,87%) de los códigos CIE-9-MC registrados en los 12 meses, correspondientes a 2.202 códigos diferentes, no fueron aceptados por esta causa. Además, en algunos casos tales códigos incompletos se refieren a problemas crónicos de salud relevantes, como son la hipertensión arterial (CIE-9-MC: 401; n=280.841), diabetes mellitus (CIE: 250; n=121.545), infarto agudo de miocardio (CIE-9-MC: 410; n= 21.490) o neoplasias malignas (CIE-9-MC: 140-208; n= 24.832).

Por ello, se recodificaron los códigos incompletos, asignándoles uno de 5 dígitos siempre que resultó factible. Tras este proceso, quedaron sin clasificar solamente 16.156 códigos (0,08%), debido a diversas causas: porque correspondían a códigos E (causas externas de lesiones); resultaban tan inespecíficos que no fue factible adjudicarles un 5º dígito; o eran cadenas alfanuméricas no válidas, sin correspondencia con el sistema CIE-9-MC.

De este modo, finalmente se pudieron clasificar 19.336.819 diagnósticos. De ellos, 6.259.725 (32,37%) fueron considerados crónicos por el programa CCI. Un esquema de todo el procedimiento seguido puede verse en la Figura 3.

Figura 3. Sistemática empleada para identificar patologías crónicas a partir de los diagnósticos codificados mediante CIE-9-MC.



3.4.2.4.2 Creación de los Grupos de Enfermedades Crónicas (GRECs):

En una segunda fase se clasificaron todas las enfermedades crónicas de la base de datos de este estudio mediante el *Clinical Classifications Software* (CCS). CCS es un sistema que categoriza también cada la totalidad de los códigos de diagnósticos CIE-9-MC en 284 grupos autoexcluyentes, clínicamente homogéneos. Sin embargo, no todas estas categorías fueron tomadas en consideración en el diseño de FINGER, puesto que algunas de ellas corresponden a problemas agudos; así, solamente 181 categorías fueron incluidas. Además, en tres casos se modificaron los grupos originales CCS:

- Para crear una categoría independiente para Obesidad.
- Para incluir en un sólo grupo la Insuficiencia Cardíaca, en vez de fraccionada en dos en función de ser resultado o no de hipertensión arterial.
- Para diferenciar las psicosis de otro tipo de diagnósticos relacionados con depresión.

Posteriormente estas agrupaciones de diagnósticos se colapsaron en un número manejable de categorías (a las que se denominó Grupos de Enfermedades Crónicas [GRECs]), aplicando los criterios siguientes:

- Algunas patologías se individualizaron por su especial relevancia, frecuencia o interés en Osakidetza para desarrollar programas específicos para su atención; entre ellas, se encuentran la diabetes mellitus (DM), obesidad, hipertensión arterial (HTA), insuficiencia cardíaca congestiva (ICC) o metástasis. En los casos en que resultó factible, este proceso se realizó a partir de la agrupación de CCS (por ejemplo, DM con y sin complicaciones se agrupan en un GREC), pero como ya se ha explicado en el párrafo anterior, en otras

ocasiones fue necesaria la creación un grupo nuevo (Obesidad) o la reclasificación de algunos códigos CIE-9-MC (por ej., los correspondientes a HTA con ICC se excluyeron del CCS para HTA y se pasaron al GREC de ICC).

- Para el resto de patologías, las categorías CCS se agruparon en función de los sistemas corporales, con tres excepciones:
 - Los problemas de salud mental, que se clasificaron en dos (Esquizofrenia y Psicosis; Otros Problemas de Salud Mental).
 - Las lesiones traumáticas de la médula espinal se incluyeron en el GREC de Sistema Nervioso. El resto de problemas traumáticos fueron excluidos.
 - Se creó un último GREC para recoger las 8 categorías CCS, que habían quedado sin agrupación (Miscelánea).

De esta manera se generaron un total de 27 GRECs (Tabla 7). La distribución de la población en estos grupos se presenta en la tabla 8.

Tabla 7.- Generación de los Grupos de Enfermedades Crónicas (GRECs) a partir de los grupos CCS (Clinical Classifications Software)

Grupos de Enfermedades Crónicas	Grupos CCS (Clinical Classifications Software) incluidos		Comentarios
	Numero	Descripción	
Enfermedades Infecciosas y Parasitarias Crónicas	1	Tuberculosis	
	5	Infección por VIH	
	6	Hepatitis	
	7	Infecciones Víricas (otras)	
	8	Otras infecciones	
	9	Infecciones de transmisión Sexual (otras)	
Neoplasias Malignas	11	Cáncer de Cabeza y Cuello	
	12	Cáncer de Esófago	
	13	Cáncer de Estómago	
	14	Cáncer de Colon	
	15	Cáncer de Resto y Ano	
	16	Cáncer de Hígado	
	17	Cáncer de Páncreas	
	18	Cáncer Gastrointestinal (otros)/peritoneal	
	19	Cáncer Bronquial/pulmonar	
	20	Cáncer Aparato Respiratorio (otros)	
	21	Cáncer Hueso/Tej. conectivo	
	22	Melanoma	
	23	Cáncer no epitelial de piel (otros)	
	24	Cáncer de Mama	
	25	Cáncer de Útero	
	26	Cáncer de Cérvix	
	27	Cáncer de Ovario	
	28	Cáncer Genital Femenino (otros)	
	29	Cáncer de Próstata	
	30	Cáncer de Testículos	
	31	Cáncer Genital Masculino (otros)	
	32	Cáncer de Vejiga	
	33	Cáncer de Riñón	
	34	Cáncer de Órganos Urinarios (otros)	
35	Cáncer de Cerebro y Sistema Nervioso		
36	Cáncer de Tiroides		
37	Enfermedad de Hodgkin		

	38	Linfoma No-Hodgkin	
	39	Leucemia	
	40	Mieloma múltiples	
	41	Otros Cánceres primarios	
	43	Neoplasia Maligna (sin especificación localización)	
	44	Neoplasia indeterminada o de comportamiento incierto	
	45	Quimioterapia y radioterapia antitumoral	
Metástasis	42	Neoplasia Maligna Secundaria	La presencia de un dx de este grupo hace que no se contabilice el GREC "Neoplasias Malignas".
Diabetes Mellitus	49	Diabetes Mellitus sin complicaciones	
	50	Diabetes Mellitus con complicaciones	
Hiperlipidemias	53	Hiperlipidemia	
Obesidad		Obesidad	Códigos CIE-9-MC: 2780 27800 27801 27802 27803 79391 V8521 V8522 V8523 V8524 V8525 V8530 V8531 V8532 V8533 V8534 V8535 V8536 V8537 V8538 V8539 V854 V8541 V8542 V8543 V8544 V8545 V8554
Otras Enf. Crónicas Endocrinológicas, Nutricionales, Metabólicas o Inmunológicas	48	Trastornos del Tiroides	
	51	Trastornos Endocrinológicos (otros)	
	52	Deficiencia Nutricional	
	54	Gota y otras Artropatías por Cristales	
	56	Fibrosis Quística	
	57	Trastornos Inmunológico	
	58	Trastornos Endocrinológicos, Nutricionales y Metabólicos (otros)	Los Códigos CIE-9-MC correspondientes a Obesidad se excluyen de este grupo
Enf. Crónicas de la sangre y Órganos Hematopoyéticos	59	Anemia Carencial y otras anemias	
	61	Anemia Falciforme	
	62	Trastornos Hemorrágicos y de la Coagulación	
	63	Trastornos Leucocitarios	
	64	Enfermedades Hematológicas	

		(otras)	
Enf. Crónicas Sistema Nervioso	77	Encefalitis	
	78	Infección del Sistema Nervios Central (otras)	
	79	Enfermedad de Parkinson	
	80	Esclerosis Múltiple	
	81	Enfermedades Hereditarias y Degenerativas del SNC	
	82	Parálisis	
	83	Epilepsia y Trastornos Convulsivos	
	84	Cefalea y Migraña	
	85	Coma, Estupor y daño Cerebral	
	95	Enfermedades Sistema Nervioso (otras)	
	227	Lesión Traumática Médula Espinal	
	Enf. Crónicas Órganos de los Sentidos	86	Cataratas
87		Trastorno de Retina	
88		Glaucoma	
89		Ceguera	
90		Infección Oftálmica	
91		Trastornos del Ojo (otros)	
92		Otitis media	
94		Trastornos del Oído (otros)	
Hipertensión Arterial	98	Hipertensión Esencial	
	99	Hipertensión con Complicaciones e Hipertensión Secundaria	Excluye los códigos CIE-9-MC: 40201 40211 40291 40401 40403 40411 40413 40491 40493, que pasan al GRE de Insuficiencia Cardíaca
Insuficiencia Cardíaca Congestiva (ICC)	108	ICC no hipertensiva	
		ICC hipertensiva	CIE-9-MC: 40201 40211 40291 40401 40403 40411 40413 40491 40493, que pasan al GRE de Insuficiencia Cardíaca
Otras enfermedades Cardíacas	96	Lesión Válvula Cardíaca	
	97	Carditis	
	100	Infarto Agudo de Miocardio	
	101	Aterosclerosis Coronaria	
	103	Enfermedad Cardíaca Pulmonar	

	104	Enfermedad Cardíaca (otras)
	105	Trastornos de Conducción
	106	Arritmia
	107	Parada Cardíaca
Enfermedad Cerebrovascular	109	Enfermedad Cerebrovascular Aguda
	110	Oclusión y estenosis de las arterias precerebrales
	111	Enfermedad Cerebrovascular (otras)
	112	Isquemia Cerebral Transitoria
	113	Efectos Tardíos de Enfermedades Cardiovasculares
Otras Enfermedades Vasculares Crónicas	114	Aterosclerosis Visceral / Periférica
	115	Aneurisma aorta/arterias periféricas
	116	Embolismo Arterial/Trombosis
	117	Enfermedad Circulatoria (otras)
	118	Flebitis
	121	Enfermedad Venas/Linfáticos (otras)
Asma	128	Asma
Enfermedad Pulmonar Obstructiva Crónica	127	Enfermedad Pulmonar Obstructiva Crónica
Otras Enfermedades Respiratorias Crónicas	122	Neumonía
	124	Enfermedad Amígdalas
	126	Enfermedad Infecciones Sistema Respiratorio Superior (otras)
	131	Insuficiencia/Parada Respiratoria
	132	Enfermedad Pulmonar debida a Agentes Externos
	133	Enfermedad Aparato Respiratorio Inferior (otras)
	134	Enfermedad Aparato Respiratorio Superior (otras)
Enf. Crónicas del aparato Digestivo	136	Enfermedad de Dientes y Mandíbula
	138	Enfermedad del Esófago
	139	Úlcera Gastroduodenal
	140	Gastritis
	141	Enfermedad del Estómago (otras)
	144	Enteritis regional/Colitis Ulcerosa
	146	Diverticulosis / Diverticulitis
	149	Enfermedad Vía Biliar
	151	Enfermedad Hepática (otras)

	152	Enfermedad Páncreas (no diabetes)
	153	Hemorragia Gastrointestinal
	155	Enfermedad Gastrointestinal (otras)
Enfermedades Crónicas del Sistema Genitourinario	156	Nefritis
	157	Insuficiencia Renal Aguda
	158	Insuficiencia Renal Crónica
	159	Infección de Tracto Urinario
	161	Enfermedad Renal (otras)
	162	Enfermedad de Vejiga (otras)
	163	Enfermedad Nefrourológica (otras)
	164	Hiperplasia de Próstata
	165	Trastornos Inflamatorios de órganos Genitales Masculinos
	166	Trastornos de órganos Genitales Masculinos (otros)
	167	Enfermedades de Mama no malignas
	168	Enfermedad Inflamatoria de Órganos Pélvicos Femeninos
	169	Endometriosis
	170	Prolapso Órganos Genitales Femeninos
	171	Trastornos Menstruales
	173	Trastornos de Menopausia
174	Infertilidad Femenina	
175	Enfermedad de Órganos Genitales Femeninos (otra)	
Enfermedades Cutáneas Crónicas	198	Enfermedad Inflamatoria de la Piel (otras)
	199	Úlcera Cutánea Crónica
	200	Enfermedad de la Piel (otras)
Enfermedades Crónicas Musculoesqueléticas y del Tejido Conectivo	201	Artritis Infecciosa y Osteomielitis
	202	Artritis reumatoide
	203	Artrosis
	204	Trastornos Articulares No Traumáticos (otros)
	205	Espondilosis, Trastorno de Disco Intervertebral y otros Problemas de Espalda
	206	Osteoporosis
	207	Fractura Patológica
	208	Deformidades Adquiridas de los Pies
	209	Deformidades Adquiridas (otras)
	210	Lupus Eritematoso Sistémico

	211	Enfermedad Tejido Conectivo (otra)	
	212	Enfermedad Ósea (otras)	
	236	Herida Abierta de Extremidades (amputaciones)	
Anomalías Congénitas	213	Anomalía Congénita Cardíaca	
	214	Anomalía Congénita Gastrointestinal	
	215	Anomalía Congénita Genitourinaria	
	216	Anomalía Congénita Sistema Nervioso	
	217	Anomalía Congénita (otras)	
Abuso de Alcohol y otras sustancias	660	Abuso de Alcohol	
	661	Abuso de Sustancias	
Esquizofrenia y otras psicosis	659	Esquizofrenia y otras psicosis	
	657	Trastorno episódicos del humor	Se han excluido los códigos ICD-9-CM: 311 y 3004
Otras Enfermedades mentales		Depresión (otras)	3004 311
	650	Reacción de Adaptación	
	651	Trastorno de Ansiedad	
	652	Trastorno de Déficit de Atención/Perturbación del Comportamiento	
	653	Delirio/ Demencia/Amnesia/ otros Trastornos Cognitivos	
	654	Trastorno del Desarrollo	
	655	Trastornos generalmente diagnosticados en la infancia/adolescencia	
	656	Trastorno de Control de Impulsos	
	658	Trastorno de Personalidad	
	663	Screening e Historia de Enfermedad Mental/Abuso de Sustancias	
	670	Miscelánea de Trastornos de Salud Mental	
Miscelánea (Enfermedades Crónicas no clasificadas en otra categoría)	47	Neoplasia Benigna (otras)	
	247	Adenopatía	
	248	Gangrena	
	253	Alergia	
	259	Trastorno No Clasificado	
	243	Intoxicación No Medicamentosa (por plomo y otros metales)	
	237	Complicación Aparato/ Implante/ Injerto	
	238	Complicación de Procedimientos Quirúrgicos o Cuidados Médicos	

CCS excluidos	2	Septicemia
	3	Infección Bacteriana (otras)
	4	Micosis
	10	Inmunización / Screening Enfermedades Infecciosas
	46	Neoplasia Benigna de Útero
	55	Trastorno Fluidos y Electrolitos
	60	Anemia Posthemorrágica Aguda
	76	Meningitis
	102	Dolor Torácico
	119	Varices Extremidades Inferiores
	120	Hemorroides
	123	Gripe
	125	Bronquitis
	129	Neumonía por Aspiración
	130	Pleuresía
	135	Infección Intestinal
	137	Enfermedades de la Boca (otras)
	142	Apendicitis
	143	Hernia Abdominal
	145	Obstrucción Intestinal
	147	Trastorno Anal/rectal
	148	Peritonitis
	154	Gastroenteritis No Infecciosa
	160	Cálculo Tracto Urinario
	172	Quiste Ovario
	176	Contracepción
	177	Aborto Espontáneo
	178	Aborto Inducido
	179	Complicaciones Postaborto
	180	Embarazo Ectópico
	181	Complicaciones embarazo (otras)
	182	Hemorragia en el Embarazo
	183	Hipertensión que complica el Embarazo
	184	Parto Prematuro
185	Embarazo Prolongado	
186	Diabetes Mellitus en el Embarazo	
187	Malposición fetal	
188	Desproporción Fetopélvica	
189	Trastorno tejidos blandos de la Pelvis	

190	Sufrimiento Fetal
191	Polihidramnios/Problemas Cavity Amniótica
192	Complicación cordón Umbilical
193	Trauma del perineo y vulva durante el período expulsivo
194	Parto por Fórceps
195	Complicación Embarazo, Parto o Puerperio que afecta a la Madre (otras)
196	Embarazo y Parto (normal y otros)
197	Infección Piel y Tejido subcutáneo
218	Recién Nacido
219	Recién Nacido de Bajo Peso
220	Hipoxia Intrauterina y Asfixia Intraparto
221	Síndrome de Distress Respiratorio
222	Ictericia Perinatal
223	Traumatismo de Nacimiento
224	Problema Perinatal (otros)
225	Luxación y Lesión Traumática Articular
226	Fractura de Cadera
228	Fractura de Cara y Cráneo
229	Fractura de Extremidad Superior
230	Fractura de Extremidad Inferior
231	Fractura (otra)
232	Esguince
233	Lesión Intracraneal
234	Lesión por aplastamiento
235	Herida Abierta Cabeza y Cuello
239	Lesión Superficial
240	Quemadura
241	Intoxicación Agentes Psicótropos
242	Intoxicación Sustancias No Medicinales
244	Lesión Traumática (otra)
245	Síncope
246	Fiebre
249	Shock
250	Nausea/Vómitos
251	Dolor Abdominal
252	Fatiga
254	Rehabilitación

	255	Problema Social /Administrativo
	256	Examen Médico
	257	Cuidados Posteriores
	258	Screening (otro)
	662	Suicidio y Lesiones Autoinfligidas

Tabla 8. Distribución de la población del País Vasco en GRECS*.

GRECS	N Pacientes	%
Enf. Infecciosas y parasitarias	5.133	0,26%
Neoplasias Malignas	33.569	1,72%
Otras Enf. Sistema Endocrino	57.862	2,97%
Diabetes Mellitus	84.697	4,35%
Hiperlipidemia	143.184	7,35%
Enf. Sangre y Org. hematopoyéticos	9.189	0,47%
Enf. Sistema Nervioso	41.153	2,11%
Enf. Org. Sentidos	66.277	3,40%
Otras Enf. Cardiacas	21.755	1,12%
HTA	197.693	10,15%
Insuficiencia Cardíaca Congestiva	11.376	0,58%
Accidente Cerebrovascular	20.216	1,04%
Otras Enf. Vasculares	14.642	0,75%
Otras Enf. Respiratorio	3.239	0,17%
EPOC	29.154	1,50%
Asma	44.080	2,26%
Enf. Aparato Digestivo	39.764	2,04%
Enf. Sistema Genitourinario	87.665	4,50%
Enf. Piel y tejido subcutáneo	20.131	1,03%
Enf. Musculoesqueléticas	110.494	5,68%
Anomalías congénitas	13.794	0,71%
Otras Enf. Mentales	124.407	6,39%
Abuso de Alcohol y sustancias	11.138	0,57%
Esquizofrenia y psicosis	9.631	0,49%
Metástasis	2.668	0,14%
Obesidad	19.503	1,00%
Miscelánea	12.019	0,62%

*Una misma persona puede estar incluida en varios grupos (excepto neoplasias y metástasis)

3.4.2.4.3.- Adjudicación de puntuaciones a los GRECs:

Para evitar problemas de sobreajuste la base de datos fue dividida en dos partes iguales: la primera fue empleada para el diseño y calibración del sistema FINGER y la segunda exclusivamente para su validación.

En la muestra de calibración se realizaron análisis de regresión lineal, utilizando como variables explicativas la presencia o no de cada GREC en los diagnósticos del primer año en cada paciente (esto es, 27 variables *dummy*) y como variable respuesta el consumo de recursos de ese individuo en el segundo año.

A partir de los estimadores obtenidos se procedió a determinar puntuaciones a cada GREC. Se decidió asignar 10 puntos al GREC con un estimador más alto (Metástasis) y, proporcionalmente, la puntuación del resto de GRECs. Con el fin de que nuestro sistema resultara de aplicación sencilla, las puntuaciones se redondearon a números enteros. Así, la puntuación obtenida por 4 GRECs fue cero, al presentar sus estimadores valores inferiores a 0,5.

Los análisis de regresión se fueron repitiendo, eliminando cada vez el GREC de puntuación más baja, hasta que quedaron solamente categorías que tuvieran una puntuación igual o superior a 1. (Tabla 9)

Tabla 9.- Puntos Asignados a cada GREC para el cálculo de puntuación por morbilidad crónica

GRECs	Puntuación
Metástasis	10
Neoplasias Malignas	4
Insuficiencia Cardíaca Congestiva	4
EPOC	4
Otras Enf. Vasculares	3
Otras Enf. Cardíacas	3
Enf. Sangre y org. hematopoyéticos	2
Diabetes Mellitus	2
Abuso de Alcohol y sustancias	2
Accidente Cerebrovascular	2
Esquizofrenia y psicosis	2
Enf. Aparato Digestivo	1
HTA	1
Asma	1
Enf. Sistema Nervioso	1
Enf. Org. Sentidos	1
Enf. Musculoesqueléticas	1
Enf. Piel y tejido subcutáneo	1
Anomalías congénitas	1
Otras Enf. Mentales	1
Enf. Sistema Genitourinario	1
Otras Enf. Sistema Endocrino	1
Miscelánea	1
Obesidad	0
Hiperlipidemia	0
Otras Enf. Respiratorio	0
Enf. Infecciosas y parasitarias	0

De este modo, cada paciente obtuvo una “puntuación por morbilidad crónica” que corresponde a la suma de los valores de sus GRECs. En cada paciente un GREC no puede sumarse más que una vez; la inclusión de múltiples diagnósticos que corresponden todos al mismo GREC en una persona no altera su puntuación.

3.4.2.4.4.- Inclusión de las variables demográficas y de utilización previa de recursos.

Como último paso, se realizaron nuevos análisis de regresión en la muestra de calibración, que emplearon como variables explicativas:

- La puntuación por morbilidad crónica.
- Grupos de edad y sexo (de 14 a 17; de 18 a 34; de 35 a 44; de 45 a 54; de 55 a 64; de 65 a 69; de 70 a 74; de 75 a 79; de 80 a 84; >=85. Cada uno de estos grupos se subdividió en varones y mujeres)
- Número anual de visitas a urgencias de hospital (0; 1+)
- Número de ingresos en hospital, excluyendo los que tuvieron como diagnóstico principal al alta las causas obstétricas o traumáticas. Para simplificar los análisis se clasificaron en cuatro categorías (0; 1; 2; 3; 4+)
- Inclusión en programa de diálisis crónica.

En base a dichos análisis, criterios clínicos y el objetivo de mantener un sistema sencillo y de utilización fácil, se aplicaron las puntuaciones que se presentan en la tabla 10.

Tabla 10.- Puntos asignados por variables demográficas y utilización año previo

EDAD		Puntuación
<45		0
45-64		1
65-74		2
75+		3
SEXO		
Varón y edad 70+		1
UTILIZACION AÑO PREVIO		
Ingresos Hospital (*)		
0		0
1		2
2		4
3		8
4+		16
Visitas Urgencias Hospital		
1+		1
Diálisis Crónica		
Sí		10

(*) Excluye causas traumáticas y obstétricas

3.4.2.5 Variables de estudio y modelos estadísticos para validación del sistema FINGER.

En la muestra de validación se construyeron diferentes modelos de regresión empleando 6 variables respuesta:

- Coste de la atención sanitaria en los 12 meses siguientes a la clasificación de cada persona.
- Requerir un consumo alto de recursos sanitarios (estar incluido en el 5% de pacientes con coste más alto de la atención en el 2º año).
- Consumo muy alto de recursos sanitarios (personas incluidas en el 1% de población con coste más alto de la atención en el 2º año).
- Ingreso urgente en el 2º año. En este caso se excluyeron las hospitalizaciones generadas por causa obstétrica o lesiones traumáticas, pues nuestro objetivo fundamental es el diseño de un modelo para la identificación de pacientes (principalmente enfermos crónicos y pluripatológicos) que puedan beneficiarse de programas de gestión de casos.
- Estancia prolongada en hospital en el 2º año (suma de días de ingreso urgente en el 2º año por causas distintas de las obstétricas y traumatológicas, superior a 11 días).
- Estancia muy prolongada en hospital en el 2º año (suma de días de ingreso urgente en el 2º año por causas distintas de las obstétricas y traumatológicas, superior a 15 días).
- Fallecimiento.

Los análisis se repitieron cuatro veces. En cada ocasión la variable independiente fue sólo una cuantitativa discreta, la que corresponde a una puntuación FINGER en función de:

- Edad y Sexo.
- Diagnósticos (Categorías GRECs)
- Suma de puntos por edad y sexo más los de diagnósticos.
- Suma de puntos por edad y sexo, diagnósticos y utilización.

Se empleó regresión lineal cuando la variable dependiente fue el coste del segundo año y regresión logística en los modelos para identificar a los pacientes que requerirán un consumo elevado de recursos, precisarán ingresos, hospitalizaciones prolongadas o fallecerán. Para evaluar y comparar los modelos se recurrió al coeficiente de determinación (R^2) para regresión lineal y área bajo la curva ROC (AUC) para la logística.

3.4.2.6 Comparación de la capacidad predictiva de FINGER con otros métodos.

La misma base de datos utilizada para diseñar y validar FINGER, así como una metodología de análisis similar, se utilizó para evaluar otros sistemas:

- La escala de Charlson (128,135) es un método ampliamente utilizado como medida de comorbilidad que ya ha sido descrito en anteriores secciones de este documento. En este estudio, se empleó el algoritmo propuesto por Quan y otros para identificar las patologías (196)). De este modo, se clasificaron los códigos CIE-9-MC de nuestra base de datos en los 17 problemas de salud incluidos en la escala: Infarto de Miocardio; Insuficiencia Cardíaca Congestiva; Enfermedad Vascul ar Periférica; Enfermedad Cerebrovascular; Demencia; Enfermedad Pulmonar Crónica; Enfermedad Reumática; Úlcera Péptica; Enfermedad Hepática Moderada; Diabetes sin Complicaciones Crónicas; Hemiplejia o Paraplejia; Enfermedad Renal; Neoplasia Maligna (excepto de piel); Enfermedad Hepática Severa; Tumor Sólido Metastásico; Infección por VIH. Para calcular la puntuación de cada persona, se aplicó a tales patologías las puntuaciones originales propuesta por Charlson (128,197).

Dado que la escala de Charlson no incluye variables demográficas ni utilización previa de servicios de salud, se decidió confrontar su capacidad para predecir el coste de la atención

sanitaria con la del sistema FINGER empleando sólo diagnósticos. Para ello se presentan los coeficientes de determinación de dos modelos de regresión lineal simple que contenían como variable respuesta el coste en el segundo año y como variable explicativa la puntuación Charlson (en el primer modelo) y la puntuación FINGER sin variables demográficas ni de utilización previa (en el segundo modelo).

- La capacidad predictiva de los sistemas de *case-mix* ACGs, CRGs y DCGs ha sido ya presentada anteriormente en los resultados correspondientes al objetivo número 2 (174). Como ya se ha explicado, se calcularon los coeficientes de determinación para predecir el coste de la atención y el AUC para identificar correctamente a los sujetos que resultaron ser grandes consumidores de recursos en el futuro, empleando modelos estadísticos basados en estos tres *case-mix*. Así mismo, se han recogido los valores de AUC para predecir hospitalizaciones del sistema ACGs que se obtuvieron en otro estudio que también empleó la misma base de datos que la del presente estudio (141).

Los tres sistemas de *case-mix* (ACGs, CRGs y DCGs) utilizan, como variable explicativas, información no requerida por FINGER, esto es, prescripciones y coste previo de la atención sanitaria por paciente. Se debe insistir que el objetivo de FINGER es proporcionar un instrumento sencillo y muy fácil de entender por los clínicos que, incluso, no contenga más variables que los que ellos mismos puedan extraer directamente de las historias clínicas. Aunque es indudable que la adición del coste previo u otras variables explicativas hubiera aumentado la capacidad predictiva de FINGER, su exclusión se ha realizado de manera deliberada en aras a su simplicidad.

Por ello, la comparación de los modelos estadísticos basados en ACGs, DCGs y CRGs con FINGER no puede resultar ecuánime. En cualquier caso, con el objetivo de poner en contexto los resultados de FINGER, se muestran los valores de R^2 y AUC de los modelos completos de esos case mix, así como los obtenidos que únicamente se basen en variables demográficas y diagnósticos.

3.4.1.7 Validación del sistema FINGER en subpoblaciones de especial interés.

Con frecuencia, las organizaciones sanitarias diseñan intervenciones que no van dirigidas a la población general sino solamente a determinados grupos poblacionales que por sus características resultan de especial interés. Con el fin de determinar la validez del sistema FINGER para predecir el consumo de recursos en tales subgrupos, los análisis arriba citados se repitieron en algunas subpoblaciones.

Tales subgrupos corresponden a:

- Pacientes ancianos. Es conocido que las personas de edad avanzada presenta mayor prevalencia de enfermedades crónicas, coexistencia de múltiples patologías en una misma persona, situaciones de incapacidad, dependencia y mayor consumo de recursos sanitarios y sociales. De hecho, el ajuste en función de variables demográficas es una práctica que se emplea con frecuencia en la planificación sanitaria. Por otra parte, el progresivo envejecimiento de la población es un fenómeno casi universal. En concreto, España se encuentra entre los países con mayor porcentaje de población mayor de 65 años a nivel internacional. Un segundo fenómeno es el llamado envejecimiento del envejecimiento: las personas de 80 ó más años constituyen en grupo cada vez más numeroso de población. Por

estos motivos, los planes de atención a las poblaciones envejecidas se encuentran entre los programas estratégicos de las organizaciones sanitarias y hemos considerado que resulta de especial interés analizar la capacidad predictiva del Sistema FINGER en 2 subgrupos: población mayor de 65 años y población mayor de 80 años.

- Enfermos que presentan algunas enfermedades crónicas prevalentes, que suponen una carga importante de morbilidad y mortalidad, aunque existe evidencia científica de que sus complicaciones podrían ser evitadas o mitigadas a través de actividades de promoción, diagnóstico precoz, prevención secundaria y tratamiento. Tales patologías son objeto de guías de práctica clínica y su atención implica un enorme coste económico y social. En nuestro caso, se han seleccionado para su análisis individualizado a las poblaciones de personas que presentan los siguientes GRECs: diabetes mellitus, insuficiencia cardiaca congestiva y enfermedad pulmonar obstructiva crónica. Las tres se encuentran entre las patologías crónicas consideradas prioritarias en nuestro país (198) y sus exacerbaciones son causa frecuente de hospitalización (199). En el País Vasco también reciben un interés especial, ya que se citan como áreas de actuación preferente en las Políticas de Salud (200) y se han desarrollado planes específicos de intervención poblacional para los pacientes con estas patologías (201,202).
- Problemas de salud que suponen un factor de riesgo importante de enfermedades cardiovasculares u otras, cuya situación resultaría modificable mediante intervenciones preventivas o de otro tipo. Por este motivo, hemos identificado a los grupos de pacientes con los siguientes GRECs: hipertensión arterial, obesidad e hiperlipidemia.

- Pacientes con problemas de salud mental o abuso de sustancias. Dadas sus características especiales, los modelos de estratificación de riesgo no se adaptan suficientemente a las peculiaridades de las personas con este tipo de patologías(203). Para comprobar la validez del sistema FINGER en esos grupos poblacionales, se seleccionaron los pacientes que presentaban estos 3 GRECs: esquizofrenia y psicosis; abuso de alcohol y sustancias; otros problemas de salud mental.

3.4.3 Resultados

3.4.3.1 Distribución de pacientes

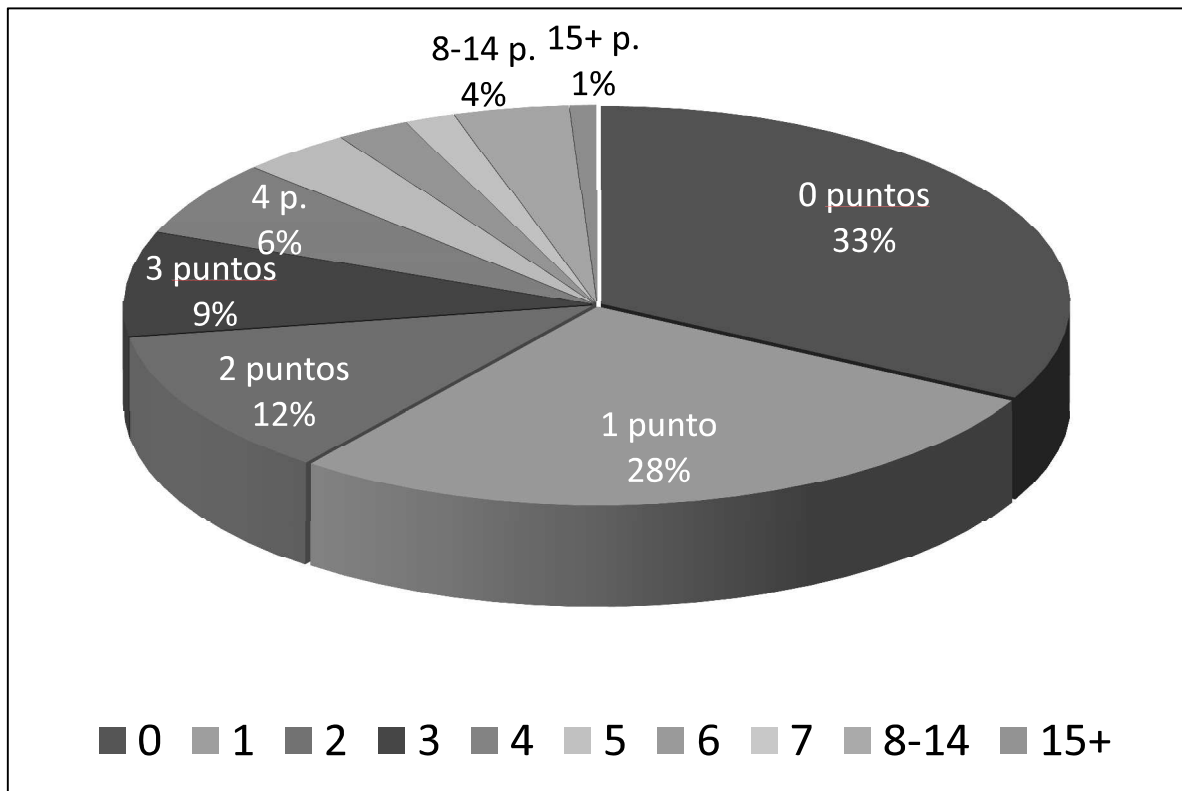
Las puntuaciones FINGER obtenidas por los pacientes oscilan entre 0 y 57, con un promedio de 2,06. Como cabía esperar la distribución está muy desplazada a la izquierda: el 33% de los pacientes no obtuvieron ningún punto, el 91% no superó los 5 puntos, mientras que sólo el 5% tuvo puntuaciones de 8 o superiores y el 1% alcanzó o superó los 15 puntos (Tabla 11 y Figura 4).

Tabla 11.- Distribución de pacientes según puntuación FINGER

Puntuación FINGER	N	%
0	639.092	32,83
1	538.370	27,65
2	232.663	11,95
3	165.533	8,50
4	119.899	6,16
5	74.163	3,81
6	48.471	2,49
7	33.434	1,72
8	23.748	1,22
9	17.159	0,88
10	12.358	0,63
11	8.708	0,45
12	6.447	0,33
13	4.977	0,26
14	3.936	0,20
15	3.112	0,16
16	2.517	0,13
17	1.972	0,10
18	1.583	0,08
19	1.347	0,07
20	1.120	0,06
21	900	0,05
22	733	0,04
23	636	0,03
24	553	0,03
25	473	0,02
26	381	0,02
27	360	0,02
28	328	0,02
29	274	0,01
30	252	0,01
31	239	0,01
32	193	0,01
33	184	0,01
34	149	0,01
35	131	0,01
36	111	0,01
37	98	0,01
38	67	0,00
39	63	0,00

40	42	0,00
41	40	0,00
42	17	0,00
43	15	0,00
44	8	0,00
45	8	0,00
46	5	0,00
47	5	0,00
48	3	0,00
49	1	0,00
50	1	0,00
51	1	0,00
53	1	0,00
54	1	0,00
55	1	0,00
57	1	0,00
Total	1.946.884	100,00

Figura 4. Distribución de los pacientes según puntuación FINGER



El coste promedio de la atención sanitaria a los pacientes en el segundo año fue 1.123€, con un rango de 0 a 144.583€. El número de pacientes con coste 0€, esto es, no utilizadores, fue de 412.900 (21,21%).

Respecto a las hospitalizaciones, se observaron los ingresos originados por causas distintas de las traumáticas y obstétricas en los 12 meses de estudio; el 3,48% de la población necesitó al menos un ingreso; 1,04% estuvo ingresado un mínimo de 12 días y 0,72% más de 15 días. Por otro lado, el porcentaje de pacientes que fallecieron fue del 0,95%.

3.4.3.2 Validación del sistema FINGER en la población general, frente a los resultados obtenidos por otros sistemas.

Mediante análisis de regresión lineal se comprobó la validez de diversos modelos para predecir el consumo de recursos en el año siguiente a la clasificación de los pacientes (Tabla 12).

Tabla 12 : Capacidad de diferentes modelos de regresión lineal para predecir el coste de la atención sanitaria en el año siguiente a la clasificación de pacientes (R²)

Variables independientes	FINGER	Charlson	ACG-PM	CRG	DCG-HCC
Edad y sexo	0,070				
Sólo diagnósticos	0,143	0,107			
Edad y sexo + diagnósticos	0,155		0,182	0,181	0,213
Edad y sexo + diagnósticos + utilización año previo	0,188				
Edad y sexo + diagnósticos + prescripciones + percentil de coste atención año previo			0,231	0,218*	0,246

*No incluye prescripciones

Un modelo que emplea solamente las variables demográficas consigue explicar un 7% de la variabilidad en el coste. La inclusión de la puntuación por morbilidad crónica mediante GRECs como única variable explicativa presentó un coeficiente de determinación de 0,143 (frente al 0,107 que obtuvo la escala Charlson).

La aplicación de un modelo con la puntuación de variables demográficas y morbilidad presentó una R^2 de 0,155 y el modelo completo (suma de puntuaciones de las variables demográficas, morbilidad y utilización previa) alcanzó 0,188.

Sobre la capacidad de estos modelos para identificar a las personas que precisaran ingresos o un elevado consumo de recursos, la edad y sexo obtuvieron una AUC en 0,74 y 0,79 (Tabla 13). Para el modelo completo, en todos los casos la AUC fue superior a 0,80, con resultados especialmente buenos para identificar a los pacientes extremos (0,88 para identificar a pacientes con coste muy alto [$P > 99\%$ de coste] y 0,86 de personas que pasaron más de 15 días ingresados). Sobre la predicción de defunción, la utilización exclusiva de variables demográficas se comportó especialmente bien (AUC=0,87) superando a la morbilidad (AUC=0,78); sin embargo, el empleo de ambas variables o la inclusión de variables demográficas, morbilidad y la utilización consiguió una AUC muy próxima a 0,90.

Los sistemas de case mix de case mix diseñados en América (cuando se calibraron localmente con nuestros datos) alcanzaron unos coeficientes de determinación para predecir el coste más altos. Los valores de R^2 para modelos basados en variables demográficas y diagnósticos oscilaron entre 0,181 y 0,213, mientras que los que incluyeron además prescripciones y coste alcanzaron cifras entre 0,218 y 0,246. En relación a los AUC para identificar a los futuros pacientes con coste alto mediante los mejores modelos, los valores se sitúan entre 0,848 - 0,868 y, en el caso de coste muy alto, entre 0,869 y 0,899. Una descripción más detallada a estos resultados se presenta en una sección anterior

de este manuscrito (“Validación en nuestro medio de sistemas de ajuste poblacional diseñados en otros países.”). La capacidad de ACGs para predecir hospitalizaciones fue objeto de otro estudio (141); los AUC fueron 0,809 (en la predicción de ingreso en los próximos 12 meses) y 0,870 (estancia en hospital de más de 12 días).

Tabla 13. Comparación de resultados de modelos predictivos: área bajo la curva (AUC)

Puntuaciones FINGER (Año1)	Variables dependientes					
	Coste alto (>P-95)	Coste muy alto (>P-99)	1+ Ingresos	Estancia Prolongada (12+ días)	Estancia MUY prolongada (>15 días)	Defunción
N	48.734	9.897	33.884	10.288	7.072	9.392
%	5,01%	1,02%	3,48%	1,06%	0,73%	0,96%
Edad y sexo	0,764	0,794	0,739	0,778	0,776	0,872
Diagnósticos	0,772	0,807	0,733	0,785	0,796	0,782
Edad y sexo + puntuación por diagnósticos	0,826	0,866	0,789	0,844	0,851	0,898
Edad y sexo + puntuación por diagnósticos + puntuación con utilización	0,838	0,875	0,802	0,854	0,861	0,896
Otros sistemas de case-mix						
Edad y sexo + diagnósticos						
ACGs	0,845	0,882				
CRGs	0,797	0,829				
DxCGs	0,846	0,884				
Edad y sexo + diagnósticos + prescripciones + percentil de coste atención año previo						
ACGs	0,868	0,897	0,809	0,870		
CRGs	0,848*	0,869*				
DxCGs	0,868	0,899				

*No incluye prescripciones

3.4.3.3 Comprobación de la validación del sistema en los grupos analizados de manera individualizada, por su especial interés.

Las subpoblaciones analizadas comprenden a todos los pacientes incluidos en la muestra de validación que se corresponden a las tipologías descritas anteriormente. Estos grupos no son autoexcluyentes: una persona que presenten múltiples patologías podrá estar clasificada en más de un grupo y todos los mayores de 80 años también están en el de mayores de 65.

- Personas de 65 o más años (n= 210.530)
- Personas de 80 o más años (n= 62.102)
- Diabetes Mellitus (n= 42.196)
- Enfermedad Pulmonar Obstructiva Crónica (EPOC) (n=14.689)
- Insuficiencia Cardíaca Congestiva (ICC) (n=5.756)
- Hiperlipidemia (n=72.046)
- Obesidad (n=9.778)
- Hipertensión Arterial (HTA) (n=99.285)
- Abuso de Alcohol y Sustancias (n=5.586)
- Esquizofrenia y Psicosis (n=4.792)
- Salud Mental: Otros problemas (n=62.301)

En la tabla 14 se muestran los resultados de los análisis de regresión lineal. La capacidad predictiva es, en general, menor en los subgrupos que en la población total, pero tal disminución no es constante. Para las variables demográficas, el rango de R^2 observadas oscila entre 0,000 y 0,075; entre 0,100 y 0,221 en los modelos que añaden diagnósticos; y entre 0,121 y 0,276 si incluyen, además, la utilización previa. En general, los grupos que contienen las personas más envejecidas o con patologías más graves (mayores de 80 años, ICC, abuso de sustancias, esquizofrenia y psicosis)

son los que presentan los coeficientes de determinación más bajos, pero de manera invariable los coeficientes del modelo completo al menos triplican los obtenidos por variables demográficas en todas las subpoblaciones.

Tabla 14: Capacidad de diferentes modelos de regresión lineal para predecir el coste de la atención sanitaria en el año siguiente a la clasificación de pacientes (R²) en diferentes subgrupos de pacientes: población envejecida, enfermos crónicos, pacientes con factores de riesgo y con problemas de salud mental.

	VARIABLE EXPLICATIVA			
	n	Puntuación Edad+sexo	Puntuación Edad+sexo+dx	Puntuación Edad+sexo+dx+utilización
POBLACION TOTAL	973.484	0,070	0,155	0,188
SUBGRUPOS				
Edad 65+	210.530	0,010	0,107	0,137
Edad 80+	62.102	0,005	0,100	0,121
Diabetes Mellitus	42.196	0,022	0,119	0,159
ICC	5.756	0,000	0,074	0,134
EPOC	14.689	0,022	0,109	0,167
Hiperlipidemia	72.046	0,043	0,160	0,203
Obesidad	9.778	0,075	0,221	0,276
HTA	99.285	0,025	0,125	0,171
Abuso de Alcohol y Sustancias	5.586	0,039	0,123	0,141
Esquizofrenia y Psicosis	4.792	0,047	0,123	0,143
Salud Mental: Otros problemas	62.301	0,069	0,159	0,195

En las subpoblaciones envejecidas, el riesgo de ingreso en hospital, ingreso prolongado, coste elevado o muy elevado prácticamente se triplica en los mayores de 65 años y se cuadruplica en los mayores de 80 (tabla 15). Por otra parte, los riesgos de fallecimiento se multiplican por 4 y por 8, respectivamente. Como cabía esperar, el comportamiento de los modelos que sólo incluyen variables demográficas es muy pobre en estas subpoblaciones. Por su parte el modelo FINGER completo consigue valores de AUC entre 0,719 y 0,759 según las variables respuesta en los mayores de 65; en los mayores de 80, se alcanzan AUC superiores a 0,70 en su capacidad de identificar a personas que requerirán consumos altos o muy altos de recursos sanitarios y hospitalizaciones prolongadas o muy prolongadas y AUC entre 0,60 y 0,70 en riesgo de hospitalización o fallecimiento.

También los enfermos crónicos tienen mayor probabilidad de ingreso, fallecimiento o gran utilización (tabla 16). En los enfermos con DM son aproximadamente 4 veces más altas que en la población general; en los pacientes con EPOC el riesgo se multiplica aproximadamente por 6 para coste elevado e ingreso, por 8 para fallecimiento y por 10 en coste muy elevado y estancias prolongadas o muy prolongadas en hospital; para los que presentan ICC, las probabilidades de coste elevado se multiplican por 9, las de ser ingresado por 10 y entre 15 y 17 para el resto de las variables respuesta. Los valores de AUC son similares en enfermos con DM y EPOC (el modelo completo consigue entre 0,70 y 0,80 en todos los casos, excepto la predicción de fallecimiento que se eleva hasta 0,801 en DM) e inferiores para ICC (valores entre 0,711 y 0,713 en coste muy elevado y estancia muy prolongada; entre 0,65 y 0,70 en las otras variables respuesta).

En la subpoblación de personas con factores de riesgo (tabla 17), la probabilidad de ingreso o coste elevado se duplica en personas con hiperlipidemia y aproximadamente se triplica en obesidad e HTA. El riesgo de fallecimiento es aproximadamente un 50% más alto en personas con hiperlipidemia u obesidad que en la población general y se triplica en personas con HTA. En estas subpoblaciones el

modelo FINGER alcanza AUC superiores a 0,80 casi en la totalidad de las variables dependientes e, incluso, a 0,90 para predecir defunciones en obesidad; valores ligeramente más bajos (entre 0,755 y 0,795) se observan en consumo elevado e ingreso en personas con hiperlipidemia o HTA; y estancia prolongada en HTA.

Por su parte, los subgrupos de personas con problemas de salud mental más graves (los diagnosticados de abuso de alcohol o sustancias y trastorno mental grave) presentaron una menor probabilidad de ingreso en hospitales generales, coste elevado e, incluso, fallecimiento. Los valores de AUC son superiores o muy próximos a 0,80 para todas las variables (Tabla 18).

Tabla 15. Comparación de resultados de modelos predictivos (área bajo la curva [AUC]) en poblaciones envejecidas (edad superior a 65 años y a 80 años).

Edad 65+ (n=210530)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	30.030	6.581	19.874	6.764	4.639	7.887
	%	14,26%	3,13%	9,44%	3,21%	2,20%	3,75%
Puntuación Edad+sexo		0,586	0,595	0,615	0,616	0,612	0,668
Puntuación Edad+sexo+dx		0,711	0,738	0,707	0,732	0,741	0,713
Puntuación Edad+sexo+dx+utilización		0,728	0,759	0,721	0,746	0,756	0,719

Edad 80+ (n=62102)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	11.260	2.424	8.609	2.912	1.928	5.088
	%	18,13%	3,90%	13,86%	4,69%	3,10%	8,19%
Puntuación Edad+sexo		0,542	0,562	0,549	0,559	0,563	0,532
Puntuación Edad+sexo+dx		0,685	0,711	0,669	0,696	0,707	0,621
Puntuación Edad+sexo+dx+utilización		0,702	0,730	0,686	0,711	0,723	0,632

Tabla 16. Comparación de resultados de modelos predictivos (área bajo la curva [AUC]) en poblaciones de enfermos crónicos (pacientes con Diabetes Mellitus, Insuficiencia Cardíaca y Enfermedad Pulmonar Obstructiva Crónica)

DM (n=42.196)							
VARIABLE EXPLICATIVA	VARIABLES RESPUESTA						
		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	8.608	2.121	5.531	2.017	1.442	1.686
%	20,40%	5,03%	13,11%	4,78%	3,42%	4,00%	
Puntuación Edad+sexo	0,631	0,619	0,629	0,633	0,629	0,716	
Puntuación Edad+sexo+dx	0,766	0,756	0,720	0,754	0,764	0,801	
Puntuación Edad+sexo+dx+utilización	0,785	0,774	0,735	0,769	0,781	0,801	

ICC (n=5.756)							
VARIABLE EXPLICATIVA	VARIABLES RESPUESTA						
		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	2.515	912	1.985	941	701	961
%	43,69%	15,84%	34,49%	16,35%	12,18%	16,70%	
Puntuación Edad+sexo	0,539	0,506	0,549	0,537	0,533	0,611	
Puntuación Edad+sexo+dx	0,666	0,667	0,659	0,663	0,678	0,650	
Puntuación Edad+sexo+dx+utilización	0,690	0,711	0,685	0,696	0,713	0,652	

EPOC (n=14.689)							
VARIABLE EXPLICATIVA	VARIABLES RESPUESTA						
		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	4.652	1.471	3.414	1.420	1.036	1.160
%	31,67%	10,01%	23,24%	10,01%	7,05%	7,90%	
Puntuación Edad+sexo	0,624	0,599	0,624	0,611	0,599	0,673	
Puntuación Edad+sexo+dx	0,717	0,729	0,703	0,729	0,728	0,764	
Puntuación Edad+sexo+dx+utilización	0,743	0,767	0,734	0,765	0,770	0,767	

Tabla 17. Comparación de resultados de modelos predictivos (área bajo la curva [AUC]) en poblaciones de pacientes con factores de riesgo (Hipertensión Arterial, Hiperlipidemia y Obesidad).

HTA (n=99.285)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	15.389	3.552	9.878	3.488	2.430	3.010
	%	15,50%	3,58%	9,95%	3,51%	2,45%	3,03%
Puntuación Edad+sexo		0,635	0,630	0,653	0,660	0,653	0,724
Puntuación Edad+sexo+dx		0,741	0,778	0,740	0,779	0,788	0,811
Puntuación Edad+sexo+dx+utilización		0,761	0,806	0,755	0,795	0,806	0,814

Hiperlipidemia (n=72.046)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	7.215	1.603	4.455	1.430	1.001	972
	%	10,01%	2,22%	6,18%	1,98%	1,39%	1,35%
Puntuación Edad+sexo		0,673	0,680	0,669	0,690	0,687	0,779
Puntuación Edad+sexo+dx		0,776	0,818	0,764	0,814	0,825	0,874
Puntuación Edad+sexo+dx+utilización		0,792	0,836	0,780	0,827	0,840	0,876

Obesidad (n=9.778)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	1.224	324	776	296	234	144
	%	12,52%	3,31%	7,94%	3,03%	2,39%	1,47%
Puntuación Edad+sexo		0,721	0,738	0,707	0,748	0,748	0,835
Puntuación Edad+sexo+dx		0,815	0,868	0,804	0,856	0,863	0,903
Puntuación Edad+sexo+dx+utilización		0,829	0,886	0,820	0,877	0,884	0,904

Tabla 18. Comparación de resultados de modelos predictivos (área bajo la curva [AUC]) en poblaciones de pacientes con problemas de salud mental (Abuso de alcohol y sustancias; Esquizofrenia y Psicosis; Otros problemas de Salud Mental)

Abuso de Alcohol y Sustancias (n=5.586)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	242	50	164	42	29	37
	%	4,33%	0,90%	2,94%	0,75%	0,52%	0,66%
Puntuación Edad+sexo		0,704	0,737	0,683	0,701	0,697	0,818
Puntuación Edad+sexo+dx		0,788	0,811	0,739	0,793	0,776	0,873
Puntuación Edad+sexo+dx+utilización		0,803	0,809	0,746	0,804	0,796	0,874

Salud Mental: Otros problemas (n=62.301)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	3.796	806	2.500	807	567	723
	%	6,09%	1,29%	4,01%	1,30%	0,91%	1,16%
Puntuación Edad+sexo		0,752	0,765	0,734	0,759	0,753	0,845
Puntuación Edad+sexo+dx		0,816	0,843	0,783	0,822	0,829	0,881
Puntuación Edad+sexo+dx+utilización		0,829	0,852	0,795	0,832	0,840	0,878

Esquizofrenia y Psicosis (n=4.792)							
VARIABLES RESPUESTA							
VARIABLE EXPLICATIVA		Coste alto (>P-95)	Coste muy alto (>p-99)	1+ ingresos	Estancia prolongada (12+ días)	Estancia muy prolongada (>15 días)	Defunción
	n	218	42	145	44	26	32
	%	4,55%	0,88%	3,03%	0,92%	0,54%	0,67%
Puntuación Edad+sexo		0,741	0,737	0,711	0,772	0,729	0,848
Puntuación Edad+sexo+dx		0,794	0,817	0,759	0,812	0,811	0,880
Puntuación Edad+sexo+dx+utilización		0,811	0,843	0,787	0,819	0,826	0,872

3.4.4 Discusión del Objetivo 4

El nuevo sistema de estratificación poblacional FINGER está diseñado para clasificar a toda la población de un área geográfica. Utiliza datos de los 12 meses previos (variables demográficas, diagnósticos y utilización de recursos) para predecir las necesidades de atención de las personas en los siguientes 12 meses. Se caracteriza por su claridad y ausencia de sofisticación. Sólo requiere datos que resultan fáciles de obtener de las historias clínicas (tanto manualmente por los clínicos, como de manera automatizada en bases de datos administrativas). Utiliza un número reducido de variables: los diagnósticos se colapsan en sólo 23 grupos de enfermedades; a ellas se añade la edad y sexo, el número de ingresos en los 12 meses anteriores, la inclusión en programa de diálisis crónica y contacto con los servicios de urgencia. Cada variable lleva asociado un peso (que oscila entre 0 y 10) y en cada paciente se obtiene un índice predictivo a partir de la suma de todos sus pesos. A pesar de su simplicidad, ofrece una capacidad suficiente para predecir el coste de la atención e identificar adecuadamente a las personas que requerirán en el futuro gran cantidad de cuidados sanitarios o sufrirán eventos no deseados, como son hospitalización no programada o defunción.

3.4.4.1 Resultados principales y comparación con otros sistemas de estratificación

El uso de variables demográficas (edad y sexo) sólo consigue predecir un 7% de la variabilidad del consumo futuro de recursos sanitarios. Por su parte, un modelo basado en la puntuación por morbilidad que ofrece FINGER alcanza el 14% y casi el 19% en el modelo completo.

Frente a ello, la agrupación de diagnósticos a través de la escala Charlson explicó el 11% de la variabilidad en esta misma población. En secciones anteriores de este mismo trabajo ya se ha descrito en detalle un estudio de investigación previo, que utilizó la misma base de datos que la

empleada para construir y validar FINGER. Dicho estudio permitió establecer que sistemas de *case-mix* muy sofisticados (como son ACGs, CRGs y DCGs) alcanzaban con sus mejores modelos estadísticos (que incluyen como variables explicativas además de la edad, el sexo y los diagnósticos otros factores como son las prescripciones y el percentil previo de coste de la atención) unos coeficientes de determinación de 0,23; 0,22 y 0,25 respectivamente (174).

Aunque los valores de los coeficientes de determinación obtenidos en el País Vasco (tanto por FINGER como por los *case-mix*) puedan parecer bajos, son equiparables a los obtenidos por otros autores, en otros sistemas de salud (82). Aunque no se ha establecido con exactitud cuál es porcentaje de variabilidad en el coste que podría llegar a predecirse mediante el empleo de sistemas de ajuste de riesgo, habitualmente se estima que su valor máximo se encontraría entre el 20 y 25% (77,204). Newhouse (77,205) considera que la variabilidad de una persona puede dividirse en tres componentes. El primero es un efecto fijo y permanente, consecuencia de las características de ese paciente que de manera invariable le situará por encima (o debajo) de la media de toda la población; por ejemplo, si un paciente presenta enfermedades crónicas, se puede esperar que el gasto de su atención sea más elevado por un tiempo indefinido. El segundo componente también tiene un impacto predecible en el coste, pero su efecto puede variar y no prolongarse en el tiempo; supongamos, la exposición a un factor de riesgo que puede modificarse en el futuro. El tercer componente es aleatorio. Según este esquema, sólo resultaría factible predecir la variabilidad atribuible al primer componente y parcialmente al segundo, lo cual supondría, en el mejor de los casos, el 20-25% de la variabilidad total. En la medida que puedan incluirse más factores correspondientes al segundo componente, este límite podría llegar a superarse, aunque no se ha determinado hasta qué punto.

Ya se ha expuesto que resulta muy difícil establecer comparaciones válidas entre los resultados de FINGER con los de los otros sistemas; unos y otros utilizan diferentes tipos de variables explicativas.

Sin embargo, consideramos que resulta conveniente presentar estos resultados, pues eso ayuda a situar en contexto los observados con FINGER.

Para evaluar la capacidad para identificar a las personas en mayor riesgo, con frecuencia se observa el AUC de los modelos. El valor de AUC corresponde a la proporción de veces en que un modelo diferencia correctamente entre dos situaciones posibles (por ejemplo, que un individuo sea de alto o de bajo riesgo); así, una cifra de 0,5 indicaría que la capacidad del modelo no es mejor que la que se obtendría por simple azar, echando una moneda al aire, mientras que un valor de 1 supondría que la sensibilidad y especificidad son óptimas. Habitualmente se considera que un modelo alcanza una capacidad discriminativa aceptable si sus cifras de AUC están entre 0,7 - 0,8 y es buena si supera el valor de 0,8 (206). Según este criterio, son buenos los valores que presenta FINGER para identificar de manera prospectiva a las personas que en el año próximo requerirán un consumo alto o muy alto de cuidados sanitarios (0,838 y 0,875), precisarán de ingresos urgentes en hospitales (0,802), de ingresos prolongados (0,861) o fallecerán (0,896).

Los resultados de FINGER son asimilables o parecidos a los de los *case-mix*. Los AUCs de tales sistemas oscilan entre 0,848 y 0,868 para coste alto; 0,869 y 0,899 en coste muy alto; 0,809 en hospitalización y 0,870 en ingresos prolongados (141,174).

Cuando se emplea FINGER para la identificación de pacientes con mayor riesgo de necesitar en el futuro recursos sanitarios costosos, ingresos en hospital, ingresos prolongados o fallecer en las subpoblaciones de pacientes envejecidos; con enfermedades crónicas; con factores de riesgo cardiovascular; o problemas de salud mental sus resultados continúan siendo buenos o aceptables. Debe tenerse en cuenta que los individuos con una enfermedad determinada tienen entre ellos una menor variabilidad que la que se observa en la población general. Por ejemplo, todos los pacientes con diabetes mellitus tienen, al menos, una puntuación FINGER de 2 (esto es, están todos situados

por encima del percentil 60) y, así mismo, una proporción mayor de ellos se concentra en los grupos de riesgo elevado; en consecuencia, resulta más difícil hacer una correcta discriminación entre ellos. En este sentido, resulta razonable comprobar que los valores AUC son menores en aquellos individuos que parten de una situación de mayor riesgo, esto es, los que presentan patologías más graves o edad muy avanzada.

Los datos de los pacientes con problemas de salud mental presentan algunas singularidades; por ejemplo, las personas con las patologías más importantes (esquizofrenia, psicosis o abuso de sustancias) tienen, aparentemente, un menor riesgo de precisar ingresos u otros recursos sanitarios que la población general. Debe tenerse en cuenta que para la clasificación de los pacientes se han empleado los diagnósticos de atención primaria, urgencias e ingresos en hospitales generales, pero no de los servicios de salud mental; por ello, la identificación de estos pacientes ha podido ser menos adecuada que en los que presentan otras enfermedades crónicas. Por otro lado, en los pacientes con patologías psiquiátricas el coste de su atención e ingresos solo corresponden a una parte de su asistencia: la proporcionada en centros diferentes de los de salud mental. Además, resulta razonable suponer que los centros de salud mental proporcionen a estas personas cuidados sanitarios por problemas que exceden esta especialidad, lo cual supone que disminuyan sus visitas o ingresos en los otros centros.

Un aspecto a destacar es que ACGs, CRGs y DCGs pueden ofrecer mucha información y describir de manera muy desagregada la morbilidad de una población. Además, al detectar los problemas de salud de las personas a partir de sus diagnósticos y de la prescripciones que se les han realizado, pueden superar algunas limitaciones que se observan por el empleo de bases de datos administrativas (98). Por ello, sus algoritmos de clasificación son complicados y exigen el empleo de programas de software cuyo uso está sujeto a licencia. Al haber sido diseñados en otros lugares, con frecuencia requieren una adaptación a las peculiaridades de los sistemas de salud que los emplean y

exigen la contratación de personal experto que se encarga del manejo del software y las bases de datos. A pesar de ello, los profesionales del País Vasco observaron con desconfianza estos modelos que ellos no son capaces de interpretar en su totalidad, lo cual, como ya se ha descrito con anterioridad, supuso una barrera importante para su implementación de la estratificación poblacional. Otro problema adicional fue el retraso en la actualización de la información. El volumen de información necesario para clasificar una población es enorme y su manejo requiere diversas tareas, como son, la depuración de bases de datos y la propia aplicación de las técnicas estadísticas. A pesar del desarrollo de la informática, estas labores suponen un espacio de tiempo de varias semanas, periodo que transcurre desde el momento en que se extraen los datos hasta que se consigue presentar a los clínicos y gestores los resultados de la clasificación de los pacientes. Además dicha clasificación de pacientes sólo pudo realizarse en determinados momentos y no de manera continuada. Por todo ello, existía un desfase entre la situación actual de un paciente y la que reflejan sus resultados en la estratificación, lo cual aumentaba el recelo de los clínicos (122).

Por el contrario, el sistema FINGER es muy sencillo: tiene una arquitectura totalmente abierta, utiliza menos variables y estas se colapsan en unos pocos grupos. La estimación del riesgo de una persona se realiza mediante una simple suma, por lo que su cálculo puede ser realizado directamente por el clínico cuando atiende a un paciente.

Un asunto adicional que debe ser tomado en consideración por las organizaciones sanitarias es el coste administrativo de implantación de sistema de ajuste de riesgo (78). Entre otros gastos, se deben estimar los derivados del empleo de los modelos predictivos. Si se opta por un sistema de case-mix diseñado en América, debe tenerse en cuenta la necesidad de adaptación a las peculiaridades locales, en función de las características demográficas, sociales, epidemiológicas y de utilización de servicios de la población. Este proceso puede no resultar sencillo y algunos autores defienden el diseño de sistemas propios (207). Además, el empleo de sistemas registrados mediante

copyright exige la adquisición de una licencia de uso que, habitualmente, supone una tarifa plana por paciente y periodo de tiempo. Algunos autores consideran que las organizaciones pueden obtener ahorros notables si desarrollan sus propios modelos predictivos (120); aunque inicialmente los costes pueden ser más altos y requieren que la organización sea capaz de encontrar y mantener un staff de epidemiólogos, economistas de la salud, expertos en estadística e informáticos, los beneficios a largo plazo pueden superar los gastos (208).

3.4.4.2 Posibles aplicaciones de FINGER en los sistemas de salud

Al igual que otros sistemas de ajuste de riesgo, la aplicación principal de FINGER es la selección de personas que puedan ser candidatos a recibir determinadas intervenciones específicas por parte de los servicios de salud. Con este instrumento puede identificarse a las personas con mayor riesgo futuro de ingreso en hospital, necesidad de hospitalizaciones prolongadas, gran consumo de recursos sanitarios o determinados tipos de patologías y diseñar programas específicos en función de sus peculiaridades.

Sin embargo, también puede ser empleado con otros objetivos, como pueden ser:

- Descripción de la carga de morbilidad y de las patologías observadas en poblaciones de distintas áreas geográficas.
- Sistema de apoyo al establecimiento de tasas capítativas más equitativas para la financiación de organizaciones sanitarias.

3.4.4.3 Limitaciones

FINGER presenta algunas limitaciones, muchas de ellas comunes a los sistemas de ajuste de riesgo y que ya han sido explicadas en otras partes de este documento. En primer lugar porque algunos factores que se sabe influyen en la necesidad de atención sanitaria o los resultados de la misma no han sido incluidos en el modelo (96). Además, es conocido que las bases administrativas de datos sanitarios pueden contener información inexacta o insuficiente en determinadas situaciones. Así, por ejemplo, puede resultar sorprendente que FINGER no asigne puntuación a las enfermedades infecciosas, incluyendo algunas tan relevantes como las causadas por VIH; una explicación puede encontrarse en el hecho de que muchos pacientes prefieren conservar este diagnóstico como confidencial (en cuyo caso, los sanitarios que les atienden mantienen esta patología sin codificar y, por tanto, no accesible a las bases de datos) y, además, en ningún caso resulta accesible la información acerca de los fármacos antirretrovirales dispensados a cada persona (por lo que la estimación del coste de la atención sanitaria a los pacientes con infección por VIH resulta en muchos casos inexacta). Por otra parte, FINGER sólo emplea los diagnósticos codificados para deducir el estado de salud de las personas y en otros estudios se ha comprobado que la inclusión adicional de otros métodos para detectar las patologías de las personas (como son las prescripciones) consiguen una mejor descripción de la morbilidad de la población (98). Además, FINGER clasifica los problemas de salud de los pacientes en unos pocos grupos de patologías (en total 23), a partir de los cuales podría resultar difícil identificar a enfermos con algunas patologías específicas. Por último, el coste previo de la atención sanitaria, variable que muestra un gran poder predictivo (83,47), tampoco está incluido en nuestro modelo.

Sin embargo, debe tenerse en cuenta que nuestro modelo pretende ser un instrumento aplicable en el mundo real y, por ello, de manera intencionada sólo se han tomado en consideración variables que se encuentran habitualmente registradas en las historias clínicas de todos los pacientes y

resultan de fácil extracción, incluso de manera manual; por este motivo se han descartado, por ejemplo, las socioeconómicas, las psicosociales o las relativas a conductas de riesgo. Por otro lado, se ha tratado de simplificar al máximo sus algoritmos, con el fin de que los clínicos pudiesen emplearlo a modo de escala y, en detrimento de una mayor granularidad, se ha tratado de generar un número razonablemente pequeño de patologías; por este motivo, además, se ha descartado obtener información procedente de prescripciones. Por último, la inclusión del coste previo de la atención puede resultar cuestionable: si bien esta variable muestra una gran capacidad predictiva se encuentra influenciado por factores distintos de la necesidad de los pacientes, como es la propia eficiencia de los servicios de salud.

4. DISCUSION.

Este trabajo incluye cuatro proyectos de investigación a lo largo de los cuales se describe la actual situación epidemiológica, en la que las enfermedades crónicas y coexistencia de múltiples patologías en un mismo paciente es una situación cada vez más común. La atención a tales pacientes supone un reto para las organizaciones sanitarias, que se ven obligadas a modificar su modelo de asistencia por otro más eficiente y adecuado a las nuevas demandas de la población. Entre otras transformaciones, es preciso adoptar un enfoque poblacional que plantee la subdivisión de la población en niveles de carga de enfermedad y, de este modo, realizar una planificación de los recursos que cubra sus necesidades de manera adaptada y proactiva. Los sistemas de ajuste de riesgo son un instrumento necesario para llevar a cabo dicha distribución en niveles y, por ello, en este documento se analiza la validez y aplicabilidad de los sistemas más difundidos, se exponen las opiniones y se refieren las barreras que perciben los clínicos para su utilización y, por último, se describe el diseño y validación de nuevo modelo de ajuste basado en diagnósticos.

4.1 IMPORTANCIA DE LA MULTIMORBILIDAD EN EL PAIS VASCO

Los resultados que nos aporta el primer manuscrito demuestran la relevancia y actualidad del estudio de la multimorbilidad. Este es un fenómeno muy frecuente, cuya presencia se incrementa con la edad y con la privación socioeconómica. Así, la presencia de 2 o más enfermedades crónicas se ha comprobado en casi una cuarta parte de la población general (23,6%), más de la mitad de los individuos de 65 años (54,3%) y las tres cuartas partes (76,4%) de los de 80 años. Las personas que viven en las áreas más desfavorecidas desde el punto de vista socioeconómico tienden a presentar más enfermedades crónicas y se observa un claro gradiente: encontramos multimorbilidad en una de

cada cinco personas que viven en las áreas de condiciones más favorables (20,5%) y una de cada cuatro entre los habitantes de las menos favorecidas (26,1%); además estas desigualdades son mayores, en términos relativos, en el sexo femenino y en grupos de edades jóvenes.

Por otra parte, existe una gran concentración de gasto sanitario en la atención a personas con patologías crónicas y, especialmente, multimorbilidad. Los enfermos crónicos, que son un 42,9% de la población, precisan del 80,57% del total de gastos sanitario (86,7 % de ingresos, 95,2 % de prescripciones); las personas con más de dos enfermedades crónicas (esto es 23,61% de la población) son responsables del 63,55% del gasto; e incluso, los pacientes con cinco o más patologías, que representa menos de un 5% de la población (4,3%), consume casi un cuarto del total de recursos (24,65%).

Sin embargo, la relación entre multimorbilidad y coste es compleja. Según los datos de nuestro estudio, el coste anual de la asistencia aumenta en función del número de enfermedades crónicas, pero este incremento no se presenta de manera lineal, sino que es más similar a una curva exponencial. Por otra parte, aunque éste es el patrón de comportamiento que hemos hallado en la mayor parte de las enfermedades, existen diversas excepciones, como es el caso de depresión y ansiedad; los pacientes con dos o más enfermedades crónicas y además el diagnóstico de ansiedad utilizan menos recursos que si sólo tuvieran ese número de enfermedades crónicas sin la presencia de la citada patología índice; algo similar sucede con depresión en los pacientes con una carga importante de multimorbilidad (cinco o más patologías crónicas). Además, en otros casos, como neoplasias malignas o enfermedades cerebrovasculares, se observa un incremento progresivo en el coste hasta alcanzar seis o más comorbilidades, pero decae cuando ese número sigue creciendo. Aunque estos hechos puedan parecer paradójicos, podemos encontrar hipótesis plausibles que los expliquen. Los pacientes con algunas patologías (como las mentales) pueden ser reacios a buscar ayuda o encontrar más barreras para acceder a los servicios sanitarios que las personas sin esos

problemas. Por otra parte, parece razonable que en algunas enfermedades especialmente graves, como las neoplasias, los tratamientos sean habitualmente más agresivos en los enfermos con menos comorbilidad que en los pacientes muy complejos que presenta una gran combinación de enfermedades crónicas.

Estos resultados tienen importancia para la financiación, planificación y gestión de los servicios de salud. En primer lugar el aumento en la prevalencia de multimorbilidad generará nuevas demandas; el envejecimiento poblacional es un hecho comprobado en muchos países desarrollados y, de hecho, el porcentaje de mayores de 65 años en el País Vasco supera el observado en el resto de España. En segundo lugar, la cronicidad y pluripatologías son más frecuentes en las zonas de mayor privación socioeconómica, por lo cual la provisión de recursos en tales áreas geográficas debe ser acorde a las necesidades de la población con el fin de evitar inequidades. La comprobación de que las poblaciones con multimorbilidad consumirán una parte sustancial del gasto sanitario obliga a la puesta en marcha de intervenciones proactivas, especialmente dirigidas a esos pacientes. Este hecho subraya la necesidad de reorganizar los modelos actuales por otros enfoques de una asistencia más integrada.

La multimorbilidad se presenta como un fenómeno complejo y los pacientes con múltiples problemas no comparten características comunes; para poder implantar programas específicos centrados en las personas, resulta necesaria la caracterización de pacientes con diferentes patrones de comorbilidad. Este hecho destaca la necesidad desarrollar instrumentos que permitan la identificación anticipada de dichas personas, como la estratificación poblacional.

4.2 VALIDACIÓN EN NUESTRO MEDIO DE SISTEMAS DE AJUSTE POBLACIONAL DISEÑADOS EN

OTROS PAÍSES.

Dado que no todas las personas tienen la misma necesidad de atención sanitaria, un único modelo de asistencia no puede adecuarse a características de cada individuo. La estratificación poblacional plantea la fragmentación de la población en subgrupos homogéneos de personas con respecto a determinadas características de interés, lo que permite seleccionar a las personas que más pueden beneficiarse de determinados programas o intervenciones. Los sistemas de ajuste de riesgo utilizan información de las pacientes para predecir su variabilidad en consumo de recursos, el coste y los resultados de la atención u otras variables y son la base de los modelos de estratificación poblacional.

Tales sistemas de ajuste proceden de los Estados Unidos de América. Nuestro estudio revela que los tres sistemas de *case-mix* más conocidos (ACG-PM, CRG y DCG-HCC) muestran una capacidad suficiente para predecir el gasto sanitario e identificar a las personas con grandes necesidades en los próximos 12 meses, en un ambiente muy distinto al que fueron diseñados y empleado otras fuentes de información, es decir, un sistema sanitario universal de financiación pública y ausencia de información procedente de *claim-data*.

Mientras que la edad y sexo solo pueden predecir el 7% de la variabilidad en el coste, los modelos que utilizan variables clínicas alcanzan una capacidad predictiva 3 veces superior, e incluso, cuando se añade el coste previo de la atención, llegan a superar el 25%. Por otra parte, los modelos *out-of-the-box* (esto es, el uso de los estimadores que proporcionan por defecto los *case-mix*, basándose en la calibración realizada por sus creadores en América) parece una alternativa razonable para organizaciones que atienden poblaciones pequeñas o que carecen de datos suficientes para realizar una calibración local.

Con respecto a la capacidad de los modelos para detectar de manera correcta a las personas que requerirán gran cantidad de recursos sanitarios, los resultados fueron también buenos. Los valores del área bajo la curva ROC superaron el valor 0,85 en la identificación de pacientes con consumo alto y casi alcanzaron 0,9 en los de muy alto.

En general, la capacidad explicativa de DCGs fue ligeramente superior (especialmente en los modelos *out-of-the-box*) y la de CRGs inferior, motivado en parte a que el software empleado en este último *case-mix* no permitió incluir prescripciones.

En nuestro estudio, el incremento en el coeficiente de determinación al añadir variables socioeconómicas fue muy escaso. Por otro lado, el empleo de modelos estadísticos jerarquizados o complejos (diferentes de OLS) no aportó ninguna ventaja.

Estos resultados concuerdan con los encontrados por otros autores y apoyan la robustez de estos sistemas de *case-mix* (92,93,209). Muestran unos resultados comparables a pesar de haber sido realizados en países con sistemas de salud de distintas peculiaridades, grupos de personas con características diferentes a las de la población general o empleando métodos de análisis diferentes. Otro hecho a resaltar es su capacidad para funcionar con los datos imperfectos que contienen las bases de datos sanitarios existentes en el mundo real (81,209); el empleo de estos sistemas requiere la utilización de fuentes de información que contienen datos recogidos originariamente para otros propósitos (por ejemplo, las historia clínicas informatizadas); las limitaciones de estas bases son conocidas (210,211) y se asume que, incluso en enfermedades crónicas relevantes, un porcentaje de los pacientes que reciben diagnósticos en un año, esta información no se repite en los códigos extraídos durante el año siguiente (81,212).

Los sistemas de estratificación se aplican en Estados Unidos (86) y en otros países europeos (87) como instrumento para lograr una financiación equitativa y para impedir prácticas perversas de

selección de pacientes. Sin embargo, en un sistema nacional de salud como el del País Vasco, donde las organizaciones sanitarias que lo componen prestan atención sanitaria a los residentes en un área geográfica y es muy limitada la competencia entre ellas, tienen otras aplicaciones, como la identificación de pacientes candidatos a las nuevas intervenciones diseñadas para mejorar la calidad y eficiencia de los cuidados. En cualquier caso, la identificación de este último grupo será de escaso interés, a menos que dentro de él se puedan diferenciar los pacientes cuyo deterioro puede ser evitado o mitigado mediante actuaciones proactivas de los que se encuentran en situaciones inmanejables.

A pesar del innegable atractivo de estos sistemas, una dificultad para su empleo generalizado es su propia sofisticación. Se basan en la clasificación de los diagnósticos mediante unos algoritmos complejos. Ofrecen mucha información sobre los problemas de salud de los pacientes y las poblaciones; categorizan los diagnósticos en grupos clínicamente relevantes (260 ACG-PM, 547 CRG y 1.013 DCG) que pueden colapsarse fácilmente en un número más pequeño hasta alcanzar el nivel de granularidad deseado. Sin embargo, como se plantea en la siguiente sección, los profesionales sanitarios observan frecuentemente con desconfianza estos modelos estadísticos, que ellos no son capaces de interpretar en su totalidad.

Como se ha descrito, una explotación exhaustiva de la información sanitaria disponible, combinada con el empleo de sistemas de *case-mix* puede ofrecer orientaciones sobre el modo de dirigir nuestros esfuerzos para mejorar la atención a los pacientes crónico. Sin embargo, para conseguir resultados positivos es necesaria la participación activa de los clínicos, que sólo se logrará si ellos entienden y apoyan este proceso.

4.3 PERCEPCIONES DE LOS CLÍNICOS ACERCA DE LA ESTRATIFICACIÓN POBLACIONAL

La aplicación de la estratificación poblacional al trabajo diario de los profesionales de atención primaria es un proceso complejo desde el punto de vista cultural y organizativo, del que participan de diversos elementos interconectados. Estos elementos guardan relación con las características de sus usuarios finales potenciales (esto es, los propios clínicos), su percepción de su trabajo diario, sus opiniones sobre las características del nuevo programa y sus experiencias con el modo en que se llevó a cabo la implantación.

Los valores y actitudes de los clínicos sobre un enfoque de salud poblacional aparecen como un factor importante. Los profesionales con una mayor perspectiva poblacional reconocen con más facilidad los beneficios potenciales de la estratificación y se muestran más favorables a su implantación. Aunque muchos clínicos consideran necesaria una modificación de su práctica habitual concediendo mayor importancia al trabajo comunitario, reconocen que su trabajo diario gira en torno a los pacientes que demandan atención y sus visitas. La superación de esta brecha entre los valores y la práctica diaria de los clínicos puede suponer un importante factor de éxito y resultaría factible mediante cambios organizativos que supongan una nueva distribución de las tareas diarias.

Las percepciones de los clínicos de atención primaria del País Vasco sobre el propio modelo predictivo también fueron analizadas. Algunos plantearon dudas sobre la validez de los modelos estadísticos, las variables incluidas o la poca consideración de factores socioeconómicos. Si bien, como se ha señalado en el apartado anterior de esta discusión, tales cuestiones habían sido respondidas por trabajos de investigación realizados en el País Vasco antes de la puesta en marcha del programa de estratificación (99,103,174), tal información no había calado suficientemente entre los profesionales. Otras quejas estaban en relación con la actualidad de la información proporcionada por la estratificación; aunque los pacientes son clasificados por los modelos

predictivos periódicamente tal clasificación no se realiza de manera continua, lo cual pueden suponer en algunos casos una discrepancia entre la situación actual de un paciente y la presentada por el programa de estratificación. También algunos clínicos percibían como una barrera el uso del sistema CIE-9-MC para clasificar diagnósticos, lo cual había sido objeto de un trabajo previo (115) o el modo en el que les presentaba la información de los pacientes en la historia clínica informatizada.

A partir de las barreras y elementos facilitadores descritos por los clínicos, resulta posible proponer algunas recomendaciones para futuras estrategias de implantación de un programa de estratificación poblacional. En primer lugar, cuanto más cercano resulte el programa a las necesidades y valores de sus usuarios finales, más fácil resultará el éxito (186). La participación de los clínicos desde las primeras fases del diseño e implantación del programa resulta un elemento importante. Su experiencia directa con los modelos predictivos, sus aplicaciones y las fases de implantación, aumentará su conocimiento del mismo y mejorará su valoración global. Un segundo elemento clave se refiere al fortalecimiento de la comunicación sobre la estratificación poblacional y sus objetivos, especialmente cuando se plantea a los profesionales que modifiquen sus actividades diarias, lo cual resultará imprescindible para realizar el paso de un enfoque centrado en el manejo individual de las demandas de sus pacientes a otro más proactivo y centradas en la gestión poblacional. Por otra parte, la estrategia de implantación debe promover la autonomía de los clínicos. Aunque en sus primeras fases, los gestores del Servicio Vasco de Salud establecieron actividades e indicadores comunes para toda la organización, otras estrategias que permitan una mayor autogestión y se adapten al contexto local e intereses propios de cada Equipo de Atención Primaria podrían obtener mejores resultados. Finalmente, la implantación del programa de estratificación debe encuadrarse en una estrategia amplia de reformas en el modelo de prestación de cuidados sanitarios. Por ello, resulta necesario una planificación cuidadosa y una comunicación fluida, con el fin de evitar un sentimiento de saturación ante los cambios en los profesionales sanitarios.

4.4 FINGER. UN NUEVO SISTEMA DE ESTRATIFICACIÓN POBLACIONAL

Por último, este trabajo describe el desarrollo y validación de un nuevo sistema de estratificación poblacional. Dicho sistema ofrece una capacidad suficiente para predecir el coste de la atención e identificar adecuadamente a las personas que requerirán en el futuro gran cantidad de cuidados sanitarios o sufrirán eventos no deseados, como son hospitalización urgente o defunción. El modelo diseñado resulta de aplicación sencilla, fácil comprensión, no requiere cálculos estadísticos complejos y sólo emplea variables accesibles en las historias clínicas. En nuestra opinión, esto último supone una fortaleza importante de FINGER, que puede compensar una menor capacidad predictiva frente a otros sistemas. Como se ha descrito en la sección anterior, con frecuencia los profesionales sanitarios se quejan de la impenetrabilidad de los métodos de clasificación de pacientes, que ellos no son capaces de comprender de manera intuitiva y cuya información les resulta difícil de interpretar.

FINGER consigue predecir un 19% de la variabilidad del consumo futuro de recursos sanitarios. Este valor puede resultar aceptable si se contrasta con los de sistemas de *case-mix* muy elaborados (como son ACGs, CRGs y DCGs) que llegan a alcanzar coeficientes de determinación de 0,23; 0,22 y 0,25 respectivamente con sus modelos estadísticos más complejos (esto es, sus variables explicativas son las prescripciones y el percentil previo de coste de la atención, además de la edad, el sexo y los diagnósticos).

Con frecuencia se acepta que un sistema de predicción de riesgo tiene una capacidad predictiva buena si su AUC supera 0,80 (206). En función de esto, debemos aceptar que FINGER obtiene buenos resultados para identificar de manera prospectiva a las personas que en el año próximo requerirán un consumo alto o muy alto de cuidados sanitarios (AUC=0,838 y 0,875 respectivamente), precisarán de ingresos urgentes en hospitales (0,802), de ingresos prolongados (0,861) o fallecerán (0,896).

Estos resultados no están muy alejados de los *case-mix* arriba citados e incluso las diferencias son proporcionalmente menores que las encontradas en los coeficientes de determinación para predecir el coste. Los AUCs de esos sistemas oscilan entre 0,848 y 0,868 para coste alto; 0,869 y 0,899 en coste muy alto; 0,809 en hospitalización y 0,870 en ingresos prolongados.

También es buena (AUC>0,80) o aceptable (AUC 0,70-0,80) la capacidad discriminadora de FINGER en subpoblaciones de pacientes envejecidos, con enfermedades crónicas, con factores de riesgo cardiovascular o problemas de salud mental. Asimismo, en estos grupos se analizó la correcta identificación de pacientes que en los 12 meses siguientes a su clasificación precisaron recursos sanitarios costosos, ingresos en hospital, ingresos prolongados o fallecieron. FINGER se comportó de manera especialmente adecuada en los pacientes con enfermedades mentales, hiperlipidemia y obesidad, mientras que los resultados fueron inferiores en insuficiencia cardiaca.

Característica del sistema FINGER

Las principales características del sistema FINGER son:

- 1.- Su objetivo es la clasificación de toda la población. Esto es, puede incluir a todos los ciudadanos de un área geográfica (por ejemplo, el País Vasco), independientemente de que hayan tenido o no ingresos u otros contactos con los servicios de salud.
- 2.- Ha sido diseñado para utilizar solo las variables incluidas en las historias clínicas. Tales variables también están contenidas en las bases administrativas de datos sanitarios. Es decir, no requiere ningún esfuerzo adicional de los clínicos para rellenar formularios o aportar más información que la que anotan de manera rutinaria en sus historias clínicas.

3.- Se basa fundamentalmente en los diagnósticos de todos los problemas de salud por los que el paciente ha tenido contacto con los servicios de salud.

4.- Su diseño es sencillo. El número de variables es limitado: los diagnósticos se colapsan en 23 grupos de enfermedades; a ellas se añade la edad y sexo, el número de ingresos en los 12 meses anteriores, la inclusión en programa de diálisis crónica y contacto con los servicios de urgencia. Cada variable lleva asociado un peso (que oscila entre 0 y 10) y en cada paciente se obtiene un índice predictivo a partir de la suma de todos sus pesos.

5.- Las variables seleccionadas son de relevancia clínica y de fácil comprensión para los profesionales sanitarios.

6.- Aunque el principal objetivo de FINGER es la estratificación poblacional, permite la identificación de poblaciones de pacientes con determinadas patologías crónicas, especialmente relevantes.

7.- La obtención del índice FINGER se puede realizar de forma automática, a partir de extracciones periódicas y así clasificar a todos los ciudadanos de la Comunidad Autónoma. Sin embargo, también es factible llevarla a cabo de manera manual a modo de escala: como se ha citado anteriormente, si un clínico desea calcular el índice de un paciente simplemente deberá observar sus patologías y las otras variables referidas y efectuar por si mismo la suma de sus pesos.

5. SINTESIS.

1.- La cronicidad y multimorbilidad son fenómenos muy frecuentes en el País Vasco. Actualmente, sólo el 57% de la población está libre de enfermedades crónicas y el promedio de estas patologías por habitante es 0,97. Además, las enfermedades crónicas tienden a concentrarse en algunas personas. La multimorbilidad está presente en el 23,6 % de la población general, 54 % de los mayores de 65 años y 76% de los que sobrepasan la edad de 85 años. Aunque resulta más infrecuente, se observa también en casi el 2% de las personas de edades comprendidas entre 0-18 años.

Existe un gradiente muy claro entre privación socioeconómica y patologías crónicas. El promedio de enfermedades por paciente entre la población que reside en las áreas más desfavorecidas supera en casi un 30% al de las que los que viven en las zonas más favorecidas. Así mismo, la prevalencia de multimorbilidad es un 30 % más elevada entre los habitantes de las zonas más pobres. Estas diferencias son mayores entre las mujeres y entre los jóvenes.

El coste anual de la atención sanitaria por paciente se incrementa en función del número de enfermedades crónicas que presentan. Sin embargo, se observan algunas peculiaridades. En primer lugar, tal crecimiento no sigue una progresión lineal, sino que se aproxima a una curva exponencial. Sin embargo, este patrón no es constante para todas las enfermedades y se ve modificado en función de las características específicas de cada enfermedad. Por tanto, la multimorbilidad se presenta como un fenómeno complejo y los pacientes con múltiples problemas no comparten características comunes. La transformación de los sistemas de salud para proporcionar una mejor atención a los pacientes crónicos y pluripatológicos supone la provisión de diferentes modelos de cuidados en función de las necesidades de las personas. La identificación de los individuos que pueden beneficiarse de cada uno de tales modelos no puede basarse en el simple recuento de enfermedades crónicas, sino que debe tener en cuenta las combinaciones de sus patologías.

2.- Los tres sistemas de *case-mix* analizados en este estudio (*Adjusted Clinical Groups* [ACG-PM], *Diagnostic Cost Groups/Hierarchical Condition Categories* [DCG-HCC] y *Clinical Risk Group* [CRG]) fueron diseñados para su empleo en organizaciones sanitarias de los Estados Unidos. Tales organizaciones tienen unas características muy distintas a las de servicios de salud como Osakidetza, que proporcionan asistencia universal y financiada mediante impuestos a toda la población. Además, las fuentes de información utilizadas en América para generar bases de datos administrativas son muy diferentes a las nuestras. Sin embargo, los sistemas *case-mix* americanos se comportaron como instrumentos robustos, cuyo empleo resulta factible en nuestro ámbito.

Su validez para predecir el consumo de recursos sanitarios en el año próximo es similar a la comprobada en su país de origen y se llegaron a obtener unos coeficientes de determinación que incluso superaron el valor 0,25. También se comprobó que su capacidad para identificar a las personas que requerirán gran cantidad de recursos sanitarios en los próximos 12 meses es buena o muy buena. Si bien los resultados son mejores en los modelos estadísticos calibrados localmente con nuestros propios datos, también resultaron aceptables los modelos basados en los estimadores que aportan por defecto los *case-mix* (esto es, los que obtuvieron en organizaciones de Estados Unidos los investigadores que los diseñaron). Esta última opción puede resultar una alternativa razonable en organizaciones que no pueden realizar una calibración local por contar con poblaciones pequeñas o no disponer de recursos para ello.

3.- La aplicación de un enfoque poblacional en el trabajo diario de los clínicos de atención primaria, resulta un proceso complejo. Supone el paso de un modelo centrado en el manejo individual de los pacientes a otro más proactivo y orientado a la gestión poblacional. Muchos clínicos conceden gran importancia al trabajo comunitario, aunque reconocen que sus actividades diarias se dedican, de manera casi exclusiva, a atender las visitas de los pacientes que demandan atención. La

estratificación poblacional puede ser un elemento que ayude a superar esta contradicción, lo cual representa una oportunidad para su difusión en atención primaria.

Sin embargo, se comprobó que existían reticencias en los clínicos para aceptar sistemas de clasificación y modelos estadísticos que ellos no comprendían en su totalidad. En consecuencia, plantearon dudas respecto a la validez de sistemas de *case-mix* diseñados en otros países, la valoración insuficiente de algunas variables (como las socioeconómicas), describieron dificultades para registrar en sus consultas los datos necesarios para clasificar a los pacientes con los case mix o se quejaron sobre los retrasos de tiempo que se producen en durante el proceso de análisis y clasificación de los pacientes, lo cual genera discrepancia entre la situación actual de los pacientes y la descrita por el programa de estratificación. Por otra parte, expresaban quejas de que sus opiniones no habían sido tenidas en cuenta para desarrollar el programa.

4.- El nuevo sistema de clasificación de pacientes, denominado FINGER, ha demostrado una capacidad suficiente para predecir el coste de la atención sanitaria e identificar a los pacientes que durante los próximos 12 meses requerirán gran cantidad de recursos sanitarios, necesitarán ingresos no programados en hospital, permanecerán hospitalizados durante periodos prolongados o presentan mayor riesgo de fallecimiento. Tales resultados se han comprobado en población general o en determinados subgrupos, como son poblaciones envejecidas, enfermos crónicos, pacientes con factores de riesgo o problemas de salud mental.

FINGER es un desarrollo propio, que emplea como punto de partida instrumentos de difusión libre, creados por la *Agency for Healthcare Research and Quality (AHRQ)* americana, que posteriormente se han reajustado para adaptarlos a las características de la población asistida por nuestro sistema de salud. Se basa fundamentalmente en los diagnósticos de todos los problemas de salud por los que el paciente ha tenido contacto con los servicios de salud y tienen un diseño sencillo. El número de

variables explicativas es limitado y puede ser empleado, tanto a partir de bases de datos administrativas para clasificar a toda la población de un área geográfica, como a modo de escala por los clínicos que quieran conocer el riesgo de los pacientes en su consulta.

A la hora de elegir un modelo de estratificación de riesgo es importante tener en cuenta su capacidad predictiva y la granularidad con que se describen los problemas de salud de la población. Sin embargo, también deben valorarse otras características. En este sentido, sistemas de *case-mix* empleados en otros países y cuya validez estadística también ha sido comprobada en nuestro medio pueden resultar difíciles de implantar en nuestras organizaciones, dadas las reticencias de los profesionales sanitarios. Un modelo más sencillo, con una arquitectura totalmente transparente y muy fácil de interpretar por los clínicos puede superar los obstáculos que ellos perciben y suponer una alternativa atractiva para aplicar programas de estratificación poblacional.

6. CONCLUSIONES.

1.- En el País Vasco, la multimorbilidad está presente en el 23,6 % de la población general, 54 % de los mayores de 65 años y 76% de los que sobrepasan la edad de 85 años. La prevalencia de multimorbilidad es un 30 % más elevada entre los habitantes de las zonas más desfavorecidas desde el punto de vista socioeconómico, siendo mayores estas diferencias entre las mujeres y entre los jóvenes.

El coste anual de la atención sanitaria por paciente se incrementa en función del número de enfermedades crónicas que presente. Sin embargo, tal crecimiento no sigue una progresión lineal y se ve modificado por las peculiaridades de cada enfermedad.

2.- Los tres sistemas de *case-mix* analizados en este estudio (Adjusted Clinical Groups [ACG-PM], Diagnostic Cost Groups/Hierarchical Condition Categories [DCG-HCC] y Clinical Risk Group [CRG]) muestran en nuestro sistema de salud una capacidad para predecir el coste de la atención similar a la comprobada en su país de origen. Los coeficientes de determinación oscilaron entre 0,18 y 0,21 para los modelos basados en diagnósticos; 0,17-0,18 en los basados en prescripciones; 0,21-0,24 para la combinación de ambos; y 0,25-0,27 si, además, se añadió el coste previo de la atención. El área bajo la curva ROC fue 0,78-0,86 para identificar a los pacientes con coste alto (superior al percentil 95) y 0,83-0,90 para coste muy alto (superior a percentil 99) en los modelos que incluyeron diagnósticos, prescripciones y coste previo. Los valores obtenidos por DCG-HCC fueron ligeramente más altos y los de CRGs los más bajos, aunque la información de prescripciones no pudo ser incluida en este último sistema.

3.- Aunque muchos clínicos reconocen la importancia al trabajo comunitario y la gestión poblacional, se detectaron diversos obstáculos para la aceptación de la estratificación poblacional. En general, los

profesionales describieron problemas para registrar la información necesaria en sus consultas, plantearon quejas sobre las variables predictivas utilizadas y se mostraron reticentes a aceptar modelos estadísticos que ellos no comprendían en su totalidad.

4.- A pesar de su diseño deliberadamente sencillo, el nuevo sistema de clasificación de pacientes denominado FINGER, ha demostrado una capacidad predictiva suficiente:

- 4-A. El coeficiente de determinación de FINGER para predecir el coste de la asistencia fue 0,19.
- 4-B. Mostró una buena capacidad para identificar a los pacientes con mayores necesidades, ya que el área bajo la curva ROC fue superior a 0,80 en todos los casos: 0,84 para identificar a los pacientes con coste alto (superior al percentil 95); 0,88 para coste muy alto (superior a percentil 99); 0,80 ingreso no programado; 0,85 hospitalización prolongada (12 ó más días en el año); 0,90 fallecimiento.
- 4-C. A pesar de incluir menos variables explicativas (entre otras el coste previo) la capacidad de FINGER para identificar poblaciones de pacientes con mayor riesgo estuvo en línea con las de otros *case-mix*, si bien la capacidad predictiva del coste no fue tan alta.
- 4-D. Cuando se analizó la capacidad predictiva de FINGER en determinadas subpoblaciones (pacientes envejecidos; con enfermedades crónicas; con factores de riesgo cardiovascular; o problemas de salud mental) sus resultados continúan siendo, en general, buenos o aceptables. Debe tenerse en cuenta que los individuos con una enfermedad determinada tienen entre ellos una menor variabilidad que la que se observa en la población general y, por tanto, resulta más difícil hacer una correcta discriminación. Así, según los coeficientes de determinación para predecir el coste fluctuaron entre 0,12 y 0,20, mientras que los resultados el área bajo la curva ROC para identificar poblaciones de riesgo fueron buenos

(AUC superior o igual a 0,80) en 28 modelos, aceptables (AUC 0,70 – 0,80) en 29 modelos e inferior a 0,7 en solamente 5.

REFERENCIAS

1. Tinetti ME, Fried TR, Boyd CM. Designing health care for the most common chronic condition--multimorbidity. *JAMA*. 2012 Jun 20;307(23):2493–4.
2. Uijen AA, van de Lisdonk EH. Multimorbidity in primary care: prevalence and trend over the last 20 years. *Eur J Gen Pract*. 2008;14 Suppl 1:28–32.
3. INEBASE. Indicadores Demograficos Básicos [base de datos en Internet]. Madrid:Instituto Nacional de Estadística; 2016, [acceso 05/02/2016]. <http://www.ine.es/dynt3/inebase/index.htm?type=pcaxis&path=/t20/p278/p01/serie/&file=pcaxis>.
4. INEBASE. Proyecciones de población 2014-2064 [base de datos en Internet]. Madrid:Instituto Nacional de Estadística; 2016, [acceso 05/02/2016]. <http://www.ine.es/jaxiT3/Tabla.htm?t=1414>.
5. Organización Mundial de la Salud (OMS). Estrategia mundial sobre régimen alimentario, actividad física y salud [Internet]. OMS; 2016 [accedido 05/02/2016]. http://www.who.int/dietphysicalactivity/factsheet_inactivity/es/.
6. Starfield B. Challenges to primary care from co- and multi-morbidity. *Prim Health Care Res Dev*. 2011 Jan;12(1):1–2.
7. Starfield B, Hankin J, Steinwachs D, Horn S, Benson P, Katz H, et al. Utilization and morbidity: random or tandem? *Pediatrics*. 1985 Feb;75(2):241–7.
8. Fortin M, Stewart M, Poitras M-E, Almirall J, Maddocks H. A systematic review of prevalence studies on multimorbidity: toward a more uniform methodology. *Ann Fam Med*. 2012 Apr;10(2):142–51.
9. Marengoni A, Angleman S, Melis R, Mangialasche F, Karp A, Garmen A, et al. Aging with multimorbidity: a systematic review of the literature. *Ageing Res Rev*. 2011 Sep;10(4):430–9.
10. Salive ME. Multimorbidity in older adults. *Epidemiol Rev*. 2013;35:75–83.
11. Barnett K, Mercer SW, Norbury M, Watt G, Wyke S, Guthrie B. Epidemiology of multimorbidity and implications for health care, research, and medical education: a cross-sectional study. *Lancet Lond Engl*. 2012 Jul 7;380(9836):37–43.
12. Ward BW, Schiller JS. Prevalence of multiple chronic conditions among US adults: estimates from the National Health Interview Survey, 2010. *Prev Chronic Dis*. 2013;10:E65.
13. Orueta JF, Nuño-Solinís R, García-Alvarez A, Alonso-Morán E. Prevalence of multimorbidity according to the deprivation level among the elderly in the Basque Country. *BMC Public Health*. 2013;13:918.
14. Nuño-Solinís R, Orueta JF, Mateos M. An Answer to Chronicity in the Basque Country: Primary Care-Based Population Health Management. *J Ambulatory Care Manage*. 2012;35(3):167–73.

15. Valderas JM, Starfield B, Sibbald B, Salisbury C, Roland M. Defining comorbidity: implications for understanding health and health services. *Ann Fam Med*. 2009 Aug;7(4):357–63.
16. Hjerpe P, Merlo J, Ohlsson H, Bengtsson Boström K, Lindblad U. Validity of registration of ICD codes and prescriptions in a research database in Swedish primary care: a cross-sectional study in Skaraborg primary care database. *BMC Med Inform Decis Mak*. 2010;10:23.
17. Blas E, Kurup AS, editors. Equity, social determinants and public health programmes [Internet]. Geneva, Switzerland: World Health Organization; 2010 [cited 2016 Feb 8]. Available from: http://www.who.int/sdhconference/resources/EquitySDandPH_eng.pdf
18. Dalstra J a. A, Kunst AE, Borrell C, Breeze E, Cambois E, Costa G, et al. Socioeconomic differences in the prevalence of common chronic diseases: an overview of eight European countries. *Int J Epidemiol*. 2005 Apr;34(2):316–26.
19. Agborsangaya CB, Lau D, Lahtinen M, Cooke T, Johnson JA. Multimorbidity prevalence and patterns across socioeconomic determinants: a cross-sectional survey. *BMC Public Health*. 2012;12:201.
20. Schäfer I, Hansen H, Schön G, Höfels S, Altiner A, Dahlhaus A, et al. The influence of age, gender and socio-economic status on multimorbidity patterns in primary care. First results from the multicare cohort study. *BMC Health Serv Res*. 2012;12:89.
21. Orueta JF, García-Álvarez A, Alonso-Morán E, Vallejo-Torres L, Nuño-Solinis R. Socioeconomic variation in the burden of chronic conditions and health care provision--analyzing administrative individual level data from the Basque Country, Spain. *BMC Public Health*. 2013;13:870.
22. Mackenbach JP, Stirbu I, Roskam A-JR, Schaap MM, Menvielle G, Leinsalu M, et al. Socioeconomic inequalities in health in 22 European countries. *N Engl J Med*. 2008 Jun 5;358(23):2468–81.
23. Bloomfield K, Grittner U, Kramer S, Gmel G. Social inequalities in alcohol consumption and alcohol-related problems in the study countries of the EU concerted action “Gender, Culture and Alcohol Problems: a Multi-national Study.” *Alcohol Alcohol Oxf Oxfs Suppl*. 2006 Nov;41(1):i26-36.
24. Esnaola S, Aldasoro E, Ruiz R, Audicana C, Pérez Y, Calvo M. [Socioeconomic inequalities in mortality in the Basque Country [Spain]]. *Gac Sanit ESPAS*. 2006 Feb;20(1):16–24.
25. Espelt A, Borrell C, Roskam AJ, Rodríguez-Sanz M, Stirbu I, Dalmau-Bueno A, et al. Socioeconomic inequalities in diabetes mellitus across Europe at the beginning of the 21st century. *Diabetologia*. 2008 Nov;51(11):1971–9.
26. Whiting D, Unwin N, Roglic G. Diabetes: equity and social determinants. In: Blas E, Kurup AS, editors Equity, social determinants and public health programmes [Internet]. Geneva, Switzerland: World Health Organization; 2010 [cited 2016 Jul 20]. Available from: http://www.who.int/sdhconference/resources/EquitySDandPH_eng.pdf

27. Salisbury C, Johnson L, Purdy S, Valderas JM, Montgomery AA. Epidemiology and impact of multimorbidity in primary care: a retrospective cohort study. *Br J Gen Pract J R Coll Gen Pract.* 2011 Jan;61(582):e12-21.
28. Glynn LG, Valderas JM, Healy P, Burke E, Newell J, Gillespie P, et al. The prevalence of multimorbidity in primary care and its effect on health care utilization and cost. *Fam Pract.* 2011 Oct;28(5):516–23.
29. Hudon C, Fortin M, Poitras M-E, Almirall J. The relationship between literacy and multimorbidity in a primary care setting. *BMC Fam Pract.* 2012;13:33.
30. Hosseinpoor AR, Bergen N, Kunst A, Harper S, Guthold R, Rekve D, et al. Socioeconomic inequalities in risk factors for non communicable diseases in low-income and middle-income countries: results from the World Health Survey. *BMC Public Health.* 2012;12:912.
31. Ahmadi B, Alimohammadian M, Yaseri M, Majidi A, Boreiri M, Islami F, et al. Multimorbidity: Epidemiology and Risk Factors in the Golestan Cohort Study, Iran: A Cross-Sectional Analysis. *Medicine (Baltimore).* 2016 Feb;95(7):e2756.
32. Martin M, Battegay E, Röcke C. Editorial: quality of life in multimorbidity. *Gerontology.* 2014;60(3):247–8.
33. Tan Z, Liang Y, Liu S, Cao W, Tu H, Guo L, et al. Health-Related Quality of Life as Measured with EQ-5D among Populations with and without Specific Chronic Conditions: A Population-Based Survey in Shaanxi Province, China. *PLoS ONE.* 2013 Jul 2;8(7):e65958.
34. Hunger M, Thorand B, Schunk M, Döring A, Menn P, Peters A, et al. Multimorbidity and health-related quality of life in the older population: results from the German KORA-age study. *Health Qual Life Outcomes.* 2011;9:53.
35. Lawson KD, Mercer SW, Wyke S, Grieve E, Guthrie B, Watt GCM, et al. Double trouble: the impact of multimorbidity and deprivation on preference-weighted health related quality of life a cross sectional analysis of the Scottish Health Survey. *Int J Equity Health.* 2013;12:67.
36. Agborsangaya CB, Lau D, Lahtinen M, Cooke T, Johnson JA. Health-related quality of life and healthcare utilization in multimorbidity: results of a cross-sectional survey. *Qual Life Res Int J Qual Life Asp Treat Care Rehabil.* 2013 May;22(4):791–9.
37. Galenkamp H, Braam AW, Huisman M, Deeg DJH. Somatic multimorbidity and self-rated health in the older population. *J Gerontol B Psychol Sci Soc Sci.* 2011 May;66(3):380–6.
38. McDaid O, Hanly MJ, Richardson K, Kee F, Kenny RA, Savva GM. The effect of multiple chronic conditions on self-rated health, disability and quality of life among the older populations of Northern Ireland and the Republic of Ireland: a comparison of two nationally representative cross-sectional surveys. *BMJ Open.* 2013;3(6).
39. Mujica-Mota RE, Roberts M, Abel G, Elliott M, Lyratzopoulos G, Roland M, et al. Common patterns of morbidity and multi-morbidity and their impact on health-related quality of life: evidence from a national survey. *Qual Life Res Int J Qual Life Asp Treat Care Rehabil.* 2015 Apr;24(4):909–18.

40. Garin N, Olaya B, Moneta MV, Miret M, Lobo A, Ayuso-Mateos JL, et al. Impact of Multimorbidity on Disability and Quality of Life in the Spanish Older Population. *PLoS ONE*. 2014 Nov 6;9(11):e111498.
41. Ryan A, Wallace E, O'Hara P, Smith SM. Multimorbidity and functional decline in community-dwelling adults: a systematic review. *Health Qual Life Outcomes*. 2015;13:168.
42. Dumbreck S, Flynn A, Nairn M, Wilson M, Treweek S, Mercer SW, et al. Drug-disease and drug-drug interactions: systematic examination of recommendations in 12 UK national clinical guidelines. *BMJ*. 2015;350:h949.
43. Hughes LD, McMurdo MET, Guthrie B. Guidelines for people not for diseases: the challenges of applying UK clinical guidelines to people with multimorbidity. *Age Ageing*. 2013 Jan;42(1):62–9.
44. Boyd CM, Darer J, Boulton C, Fried LP, Boulton L, Wu AW. Clinical practice guidelines and quality of care for older patients with multiple comorbid diseases: implications for pay for performance. *JAMA*. 2005 Aug 10;294(6):716–24.
45. Luijckx H, Lucassen P, van Weel C, Loeffen M, Lagro-Janssen A, Schermer T. How GPs value guidelines applied to patients with multimorbidity: a qualitative study. *BMJ Open*. 2015;5(10):e007905.
46. Higashi T, Wenger NS, Adams JL, Fung C, Roland M, McGlynn EA, et al. Relationship between number of medical conditions and quality of care. *N Engl J Med*. 2007 Jun 14;356(24):2496–504.
47. Min LC, Wenger NS, Fung C, Chang JT, Ganz DA, Higashi T, et al. Multimorbidity is associated with better quality of care among vulnerable elders. *Med Care*. 2007 Jun;45(6):480–8.
48. Magnan EM, Palta M, Johnson HM, Bartels CM, Schumacher JR, Smith MA. The impact of a patient's concordant and discordant chronic conditions on diabetes care quality measures. *J Diabetes Complications*. 2015 Mar;29(2):288–94.
49. Ricci-Cabello I, Stevens S, Kontopantelis E, Dalton ARH, Griffiths RI, Campbell JL, et al. Impact of the Prevalence of Concordant and Discordant Conditions on the Quality of Diabetes Care in Family Practices in England. *Ann Fam Med*. 2015 Nov;13(6):514–22.
50. Turner BJ, Hollenbeak CS, Weiner M, Ten Have T, Tang SSK. Effect of unrelated comorbid conditions on hypertension management. *Ann Intern Med*. 2008 Apr 15;148(8):578–86.
51. Panagioti M, Stokes J, Esmail A, Coventry P, Cheraghi-Sohi S, Alam R, et al. Multimorbidity and Patient Safety Incidents in Primary Care: A Systematic Review and Meta-Analysis. *PloS One*. 2015;10(8):e0135947.
52. Min L, Kerr EA, Blaum CS, Reuben D, Cigolle C, Wenger N. Contrasting effects of geriatric versus general medical multimorbidity on quality of ambulatory care. *J Am Geriatr Soc*. 2014 Sep;62(9):1714–21.
53. Zulman DM, Asch SM, Martins SB, Kerr EA, Hoffman BB, Goldstein MK. Quality of care for patients with multiple chronic conditions: the role of comorbidity interrelatedness. *J Gen Intern Med*. 2014 Mar;29(3):529–37.

54. Tarrant C, Windridge K, Baker R, Freeman G, Boulton M. "Falling through gaps": primary care patients' accounts of breakdowns in experienced continuity of care. *Fam Pract*. 2015 Feb 1;32(1):82–7.
55. Shadmi E, Boyd CM, Hsiao C-J, Sylvia M, Schuster AB, Boulton C. Morbidity and older persons' perceptions of the quality of their primary care. *J Am Geriatr Soc*. 2006 Feb;54(2):330–4.
56. Paddison CAM, Saunders CL, Abel GA, Payne RA, Campbell JL, Roland M. Why do patients with multimorbidity in England report worse experiences in primary care? Evidence from the General Practice Patient Survey. *BMJ Open*. 2015;5(3):e006172.
57. Agency for Healthcare Research and Quality. Guide to Prevention Quality Indicators: Hospital Admission for Ambulatory Care Sensitive Conditions. Version 3.1; 2007. Disponible en: http://qualityindicators.ahrq.gov/downloads/modules/pqi/v31/pqi_technical_specs_v31.pdf.
58. Saver BG, Wang C-Y, Dobie SA, Green PK, Baldwin L-M. The central role of comorbidity in predicting ambulatory care sensitive hospitalizations. *Eur J Public Health*. 2014 Feb;24(1):66–72.
59. Wolff JL, Starfield B, Anderson G. Prevalence, expenditures, and complications of multiple chronic conditions in the elderly. *Arch Intern Med*. 2002 Nov 11;162(20):2269–76.
60. Payne RA, Abel GA, Guthrie B, Mercer SW. The effect of physical multimorbidity, mental health conditions and socioeconomic deprivation on unplanned admissions to hospital: a retrospective cohort study. *CMAJ Can Med Assoc J J Assoc Medicale Can*. 2013 Mar 19;185(5):E221–228.
61. Gobierno Vasco. País Vasco: transformando el Sistema de Salud 2009 - 2012 [Internet]. Vitoria-Gasteiz: Eusko Jaurlaritzaren Argitalpen Zerbitzu Nagusia Servicio Central de Publicaciones del Gobierno Vasco; 2012 [cited 2016 Feb 13]. Available from: http://www.osakidetza.euskadi.eus/contenidos/informacion/estrategia_cronicidad/es_cronicos/adjuntos/transformando_sistema_salud.pdf
62. DH/Long Term Conditions. Raising the Profile of Long Term Conditions Care: A Compendium of Information [Internet]. Produced by COI for the Department of Health; 2008 Jan [cited 2016 Feb 13]. Available from: http://webarchive.nationalarchives.gov.uk/20130107105354/http://dh.gov.uk/prod_consum_dh/groups/dh_digitalassets/documents/digitalasset/dh_082067.pdf
63. Yoon J, Zulman D, Scott JY, Maciejewski ML. Costs associated with multimorbidity among VA patients. *Med Care*. 2014 Mar;52 Suppl 3:S31–36.
64. Zulman DM, Pal Chee C, Wagner TH, Yoon J, Cohen DM, Holmes TH, et al. Multimorbidity and healthcare utilisation among high-cost patients in the US Veterans Affairs Health Care System. *BMJ Open*. 2015;5(4):e007771.
65. García-Goñi M, Hernández-Quevedo C, Nuño-Solinís R, Paolucci F. Pathways towards chronic care-focused healthcare systems: Evidence from Spain. *Health Policy*. 2012 Diciembre;108(2–3):236–45.

66. Lehnert T, Heider D, Leicht H, Heinrich S, Corrieri S, Luppá M, et al. Review: health care utilization and costs of elderly persons with multiple chronic conditions. *Med Care Res Rev MCRR*. 2011 Aug;68(4):387–420.
67. van Oostrom SH, Picavet HSJ, de Bruin SR, Stirbu I, Korevaar JC, Schellevis FG, et al. Multimorbidity of chronic diseases and health care utilization in general practice. *BMC Fam Pract*. 2014;15:61.
68. Starfield B, Lemke KW, Herbert R, Pavlovich WD, Anderson G. Comorbidity and the use of primary care and specialist care in the elderly. *Ann Fam Med*. 2005 Jun;3(3):215–22.
69. van den Bussche H, Schön G, Kolonko T, Hansen H, Wegscheider K, Glaeske G, et al. Patterns of ambulatory medical care utilization in elderly patients with special reference to chronic diseases and multimorbidity--results from a claims data based observational study in Germany. *BMC Geriatr*. 2011;11:54.
70. Bähler C, Huber CA, Brüngger B, Reich O. Multimorbidity, health care utilization and costs in an elderly community-dwelling population: a claims data based observational study. *BMC Health Serv Res*. 2015;15:23.
71. Schneider KM, O'Donnell BE, Dean D. Prevalence of multiple chronic conditions in the United States' Medicare population. *Health Qual Life Outcomes*. 2009;7:82.
72. König H-H, Leicht H, Bickel H, Fuchs A, Gensichen J, Maier W, et al. Effects of multiple chronic conditions on health care costs: an analysis based on an advanced tree-based regression model. *BMC Health Serv Res*. 2013;13:219.
73. Schoen C, Osborn R, Doty MM, Squires D, Peugh J, Applebaum S. A survey of primary care physicians in eleven countries, 2009: perspectives on care, costs, and experiences. *Health Aff Proj Hope*. 2009 Dec;28(6):w1171-1183.
74. Wagner EH, Austin BT, Von Korff M. Organizing care for patients with chronic illness. *Milbank Q*. 1996;74(4):511–44.
75. Bodenheimer T, Wagner EH, Grumbach K. Improving primary care for patients with chronic illness: the chronic care model, Part 2. *JAMA*. 2002 Oct 16;288(15):1909–14.
76. Coleman K, Austin BT, Brach C, Wagner EH. Evidence on the Chronic Care Model in the new millennium. *Health Aff Proj Hope*. 2009 Feb;28(1):75–85.
77. Newhouse JP, Buntin MB, Chapman JD. Risk adjustment and Medicare: taking a closer look. *Health Aff Proj Hope*. 1997 Oct;16(5):26–43.
78. American Academy of Actuaries. Risk Assessment and Risk Adjustment [Internet]. Washington, DC: American Academy of Actuaries; 2010 May [cited 2016 Feb 18]. Available from: http://www.actuary.org/pdf/health/Risk_Adjustment_Issue_Brief_Final_5-26-10.pdf
79. Schone E, Brown RS. Risk adjustment: what is the current state of the art, and how can it be improved? [Internet]. Princeton, NJ: Robert Wood Johnson Foundation; 2013 Jul [cited 2016 Feb 17]. (Research Synthesis Report). Report No.: 25. Available from:

www.rwjf.org/en/library/research/2013/07/risk-adjustment—what-is-the-current-state-of-the-art-and-how-c.html

80. Health Policy Brief: Risk Adjustment in Health Insurance. Risk Adjustment in Health Insurance. [Internet]. Health Affairs; 2012 August [cited 2016 Feb 18]. Available from: http://www.healthaffairs.org/healthpolicybriefs/brief.php?brief_id=74
81. Ellis R. Risk adjustment in Health care markets. In: Lu M, Jonsson E, eds Financing Health Care: New Ideas for a Changing Society. Weinheim, RFG: Wiley-VCH; 2007. p. 177–219.
82. Winkelman R, Mehmud S. A Comparative Analysis of Claims-Based Tools for Health Risk Assessment [Internet]. Society of Actuaries; 2007 [cited 2015 Nov 16]. Available from: <http://www.soa.org/Files/Research/Projects/risk-assessmenttc.pdf>.
83. Ash AS, Zhao Y, Ellis RP, Schlein Kramer M. Finding future high-cost cases: comparing prior cost versus diagnosis-based methods. Health Serv Res. 2001 Dec;36(6 Pt 2):194–206.
84. Monheit AC. Persistence in health expenditures in the short run: prevalence and consequences. Med Care. 2003 Jul;41(7 Suppl):III53-III64.
85. Ingber MJ. Implementation of risk adjustment for Medicare. Health Care Financ Rev. 2000;21(3):119–26.
86. Weiner JP, Trish E, Abrams C, Lemke K. Adjusting for risk selection in state health insurance exchanges will be critically important and feasible, but not easy. Health Aff Proj Hope. 2012 Feb;31(2):306–15.
87. van de Ven WPMM, Beck K, Van de Voorde C, Wasem J, Zmora I. Risk adjustment and risk selection in Europe: 6 years later. Health Policy Amst Neth. 2007 Oct;83(2–3):162–79.
88. Cid C, Ellis R, Vargas V, Wasem J, Prieto L. Global Risk-Adjusted Payment Models. In: Handbook of Global Health Economics and Public Policy. 2016. p. Capitulo 11.
89. Salem-Schatz S, Moore G, Rucker M, Pearson SD. The case for case-mix adjustment in practice profiling. When good apples look bad. JAMA. 1994 Sep 21;272(11):871–4.
90. DesHarnais SI, Forthman MT, Homa-Lowry JM, Wooster LD. Risk-adjusted clinical quality indicators: indices for measuring and monitoring rates of mortality, complications, and readmissions. Qual Manag Health Care. 2000;9(1):14–22.
91. Austin PC, van Walraven C, Wodchis WP, Newman A, Anderson GM. Using the Johns Hopkins Aggregated Diagnosis Groups (ADGs) to predict mortality in a general adult population cohort in Ontario, Canada. Med Care. 2011 Oct;49(10):932–9.
92. Meenan RT, Goodman MJ, Fishman PA, Hornbrook MC, O’Keeffe-Rosetti MC, Bachman DJ. Using risk-adjustment models to identify high-cost risks. Med Care. 2003 Nov;41(11):1301–12.
93. Weir S, Awew G, Clark RE. Case selection for a Medicaid chronic care management program. Health Care Financ Rev. 2008;30(1):61–74.

94. Haas LR, Takahashi PY, Shah ND, Stroebe RJ, Bernard ME, Finnie DM, et al. Risk-stratification methods for identifying patients for care coordination. *Am J Manag Care*. 2013 Sep;19(9):725–32.
95. Iezzoni, Lisa I. Risk Adjustment for Assessing Quality of Care. In: Goldfield, Norbert, Nash, David B, editors. *Managing Quality of Care in a Cost-Focused Environment*. Tampa, Florida: ACPE/Aspen Publication; 1999.
96. Rosen AK, Reid R, Broemeling A-M, Rakovski CC. Applying a risk-adjustment framework to primary care: can we improve on existing measures? *Ann Fam Med*. 2003 Jun;1(1):44–51.
97. Thomas AJ, Eberly LE, Davey Smith G, Neaton JD, Multiple Risk Factor Intervention Trial (MRFIT) Research Group. ZIP-code-based versus tract-based income measures as long-term risk-adjusted mortality predictors. *Am J Epidemiol*. 2006 Sep 15;164(6):586–90.
98. Orueta JF, Nuño-Solinis R, Mateos M, Vergara I, Grandes G, Esnaola S. Monitoring the prevalence of chronic conditions: which data should we use? *BMC Health Serv Res*. 2012;12:365.
99. Orueta JF, Lopez-De-Munain J, Báez K, Aiarzaguena JM, Aranguren JI, Pedrero E. Application of the ambulatory care groups in the primary care of a European national health care system: does it work? *Med Care*. 1999 Mar;37(3):238–48.
100. Inoriza JM, Coderch J, Carreras M, Vall-Llosera L, García-Goñi M, Lisbona JM, et al. [Measurement of morbidity attended in an integrated health care organization]. *Gac Sanit SESPAS*. 2009 Feb;23(1):29–37.
101. García-Goñi M, Ibern P, Inoriza JM. Hybrid risk adjustment for pharmaceutical benefits. *Eur J Health Econ HEPAC Health Econ Prev Care*. 2009 Jul;10(3):299–308.
102. Johns Hopkins ACG System [Internet]. [cited 2016 Feb 19]. Available from: http://acg.jhsph.org/index.php?option=com_content&view=article&id=46&Itemid=61
103. Orueta J-F, Urraca J, Berraondo I, Darpón J, Aurrekoetxea J-J. Adjusted Clinical Groups (ACGs) explain the utilization of primary care in Spain based on information registered in the medical records: a cross-sectional study. *Health Policy Amst Neth*. 2006 Mar;76(1):38–48.
104. DxCG Risk Analytics Solutions [Internet]. [cited 2016 Feb 19]. Available from: <https://www.veriskhealth.com/answers/population-answers/dxCG-risk-analytics>
105. Clinical Risk Grouping Software: 3M Health Information Systems - US [Internet]. [cited 2016 Feb 19]. Available from: http://solutions.3m.com/wps/portal/3M/en_US/Health-Information-Systems/HIS/Products-and-Services/Products-List-A-Z/Clinical-Risk-Grouping-Software/
106. Nuño R, Contel J, Orueta J, García A, Lewis G. Development and implementation risk stratification tools: Practical tools to identify patients of with complex needs. [Internet]. Vol. Working Papers. O+berri; 2013. Available from: <http://oberri.org/wp-content/uploads>
107. Orueta JF, Mateos Del Pino M, Barrio Beraza I, Nuño Solinis R, Cuadrado Zubizarreta M, Sola Sarabia C. [Stratification of the population in the Basque Country: results in the first year of implementation]. *Atencion Primaria Soc Esp Med Fam Comunitaria*. 2013 Jan;45(1):54–60.

108. Departamento de Sanidad y Consumo del Gobierno Vasco. Estrategia para afrontar el reto de la cronicidad en Euskadi. Vitoria-Gasteiz: Editado por Eusko Jaularitza - Gobierno Vasco; 2010.
109. Orueta JF. Uso del sistema ACG en atención primaria: experiencia en el País Vasco. In Sevilla; 2009.
110. Ministerio de Sanidad, Servicios Sociales e Igualdad. Registro de Altas de los Hospitales Generales del Sistema Nacional de Salud. CMBD. Norma Estatal [Internet]. Available from: <http://www.msc.es/estadEstudios/estadisticas/cmbd.htm>
111. Álvarez Bartolomé M. Nuevo modelo de datos del CMBD [Internet]. Available from: http://www.msssi.gob.es/estadEstudios/estadisticas/sisInfSanSNS/IIJornadaCIE10/CIE10_NuevoModeloDatos.pdf
112. Ministerio de Sanidad, Servicios Sociales e Igualdad. eCIE9MC. Edición electrónica de la CIE-9-MC. Clasificación Internacional de Enfermedades 9.ª Revisión, Modificación Clínica [Internet]. 2014. Available from: http://eciemaps.mspsi.es/ecieMaps/browser/index_9_mc.html
113. Hornbrook MC, Hurtado AV, Johnson RE. Health care episodes: definition, measurement and use. *Med Care Rev.* 1985;42(2):163–218.
114. WHO Collaborating Centre for Drug Statistics Methodology. ATC/DDD Index 2016 [Internet]. 2015. Available from: http://www.whocc.no/atc_ddd_index/
115. Orueta JF, Urraca J, Berraondo I, Darpón J. [Can primary care physicians use the ICD-9-MC? An evaluation of the quality of diagnosis coding in computerized medical records]. *Gac Sanit SESPAS.* 2006 Jun;20(3):194–201.
116. Dunbar L. Using ACG in Health Management Programs at Johns Hopkins. Jornada sobre Experiencias en Atención Primaria y Áreas Integradas. In Sevilla; 2009.
117. Perla RJ, Bradbury E, Gunther-Murphy C. Large-scale improvement initiatives in healthcare: a scan of the literature. *J Healthc Qual Off Publ Natl Assoc Healthc Qual.* 2013 Feb;35(1):30–40.
118. Berwick DM. Disseminating innovations in health care. *JAMA.* 2003 Apr 16;289(15):1969–75.
119. Ferlie E, Fitzgerald L, Wood M. The nonspread of innovations: the mediating role of professionals. *Acad Manag J.* 2005;48:117–34.
120. Gillespie J, Huckel Schneider C, Wilson A, Elshaug A. Implementing system - wide risk stratification approaches – critical success and failure factors: an Evidence Check rapid review brokered by the Sax Institute (www.saxinstitute.org.au) for the NSW Agency for Clinical Innovation 2015 [Internet]. [cited 2016 Apr 16]. Available from: <http://apo.org.au/files/Resource/implementing-system-wide-risk-stratification-approaches.pdf>
121. Lewis G. Predictive modelling in action: How “Virtual Wards” help high risk patients receive hospital care at home. *Issues Int Health Policy.* 2010 Aug;94:1–16.

122. Freund T, Wensing M, Geissler S, Peters-Klimm F, Mahler C, Boyd CM, et al. Primary care physicians' experiences with case finding for practice-based care management. *Am J Manag Care*. 2012 Apr;18(4):e155-161.
123. National Health Service Scotland. Investigating the use of SPARRA. Phase 1 - How and to what extent is SPARRA being used? ISD Scotland, 2011 [Internet]. [cited 2016 Apr 16]. Available from: <http://apo.org.au/files/Resource/implementing-system-wide-risk-stratification-approaches.pdf>
124. Porter A, Kingston MR, Evans BA, Hutchings H, Whitman S, Snooks H. It could be a "Golden Goose": a qualitative study of views in primary care on an emergency admission risk prediction tool prior to implementation. *BMC Fam Pract*. 2016;17(1):1.
125. Lewis GH, Curry N, Bardsley M. Choosing a predictive risk model: a guide for commissioners in England [Internet]. London, UK: The Nuffield Trust; 2011 Nov [cited 2016 Jul 13]. (Evidence for better healthcare). Available from: http://www.nuffieldtrust.org.uk/sites/files/nuffield/publication/choosing_predictive_risk_model_guide_for_commissioners_nov11.pdf
126. Curry N, Billings J, Darin B, Dixon J, Williams M, Wennberg D. Predictive Risk Project Literature Review. [Internet]. London, UK: The King's Fund.; [cited 2016 Jul 13]. Available from: http://www.kingsfund.org.uk/sites/files/kf/field/field_document/predictive-risk-literature-review-june2005.pdf
127. Allaudeen N, Schnipper JL, Orav EJ, Wachter RM, Vidyarthi AR. Inability of providers to predict unplanned readmissions. *J Gen Intern Med*. 2011 Jul;26(7):771–6.
128. Charlson ME, Pompei P, Ales KL, MacKenzie CR. A new method of classifying prognostic comorbidity in longitudinal studies: development and validation. *J Chronic Dis*. 1987;40(5):373–83.
129. Elixhauser A, Steiner C, Harris DR, Coffey RM. Comorbidity measures for use with administrative data. *Med Care*. 1998 Jan;36(1):8–27.
130. Li B, Evans D, Faris P, Dean S, Quan H. Risk adjustment performance of Charlson and Elixhauser comorbidities in ICD-9 and ICD-10 administrative databases. *BMC Health Serv Res*. 2008;8:12.
131. Bernabeu-Wittel M, Ollero-Baturone M, Moreno-Gaviño L, Barón-Franco B, Fuertes A, Murcia-Zaragoza J, et al. Development of a new predictive model for polypathological patients. The PROFUND index. *Eur J Intern Med*. 2011 Jun;22(3):311–7.
132. Huntley AL, Johnson R, Purdy S, Valderas JM, Salisbury C. Measures of multimorbidity and morbidity burden for use in primary care and community settings: a systematic review and guide. *Ann Fam Med*. 2012 Apr;10(2):134–41.
133. Charlson ME, Charlson RE, Peterson JC, Marinopoulos SS, Briggs WM, Hollenberg JP. The Charlson comorbidity index is adapted to predict costs of chronic disease in primary care patients. *J Clin Epidemiol*. 2008 Dec;61(12):1234–40.

134. Brilleman SL, Gravelle H, Hollinghurst S, Purdy S, Salisbury C, Windmeijer F. Keep it simple? Predicting primary health care costs with clinical morbidity measures. *J Health Econ.* 2014 May;35:109–22.
135. University of Manitoba. Manitoba Centre for Health Policy. Concept: Charlson Comorbidity Index [Internet]. [cited 2016 Jul 13]. Available from: <http://mchp-appserv.cpe.umanitoba.ca/viewConcept.php?conceptID=1098#HISTORICAL>
136. Alonso-Morán E, Orueta JF, Fraile Esteban JI, Arteagoitia Axpe JM, Marqués González ML, Toro Polanco N, et al. Multimorbidity in people with type 2 diabetes in the Basque Country (Spain): Prevalence, comorbidity clusters and comparison with other chronic patients. *Eur J Intern Med.* 2015 Apr;26(3):197–202.
137. García-Goñi M, Nuño-Solinís R, Orueta JF, Paolucci F. Is utilization of health services for HIV patients equal by socioeconomic status? Evidence from the Basque country. *Int J Equity Health.* 2015;14(1):110.
138. Alonso-Morán E, Orueta JF, Nuño-Solinís R. Incidence of severe hypoglycaemic episodes in patients with type 2 diabetes in the Basque country: impact on healthcare costs. *BMC Health Serv Res.* 2015;15:207.
139. Alonso-Morán E, Nuño-Solinís R, Orueta JF, Fernandez-Ruanova B, Alday-Jurado A, Gutiérrez-Fraile E. Health-related quality of life and multimorbidity in community-dwelling telecare-assisted elders in the Basque Country. *Eur J Intern Med.* 2015 Apr;26(3):169–75.
140. Nuño-Solinís R, Rodríguez-Pereira C, Alonso-Morán E, Orueta JF. Comorbidity and healthcare expenditure in women with osteoporosis living in the basque country (Spain). *J Osteoporos.* 2014;2014:205954.
141. Orueta Mendia JF, García-Álvarez A, Alonso-Morán E, Nuño-Solinís R. [Development of a predictive risk model for unplanned admissions in the Basque Country]. *Rev Esp Salud Pública.* 2014 Apr;88(2):251–60.
142. Orueta JF, García-Alvarez A, Grandes G, Nuño-Solinís R. Variability in potentially preventable hospitalisations: an observational study of clinical practice patterns of general practitioners and care outcomes in the Basque Country (Spain). *BMJ Open.* 2015;5(5):e007360.
143. Orueta JF, García-Alvarez A, Grandes G, Nuño-Solinís R. The Origin of Variation in Primary Care Process and Outcome Indicators: Patients, Professionals, Centers, and Health Districts. *Medicine (Baltimore).* 2015 Aug;94(31):e1314.
144. Orueta JF, García-Álvarez A, García-Goñi M, Paolucci F, Nuño-Solinís R. Prevalence and costs of multimorbidity by deprivation levels in the basque country: a population based study using health administrative databases. *PLoS One.* 2014;9(2):e89787.
145. OCDE. Meeting the Challenge of Ageing and Multiple Morbidities [Internet]. Paris, France: OECD Publishing; 2011 [cited 2016 Aug 16]. Available from: <http://www.oecd-ilibrary.org/content/book/9789264122314-en>

146. Vogeli C, Shields AE, Lee TA, Gibson TB, Marder WD, Weiss KB, et al. Multiple chronic conditions: prevalence, health consequences, and implications for quality, care management, and costs. *J Gen Intern Med.* 2007 Dec;22 Suppl 3:391–5.
147. Boyd CM, Fortin M. Future of Multimorbidity Research: How Should Understanding of Multimorbidity Inform Health System Design? *Public Health Rev.* 2010;32:451–74.
148. Smith SM, Soubhi H, Fortin M, Hudon C, O’Dowd T. Managing patients with multimorbidity: systematic review of interventions in primary care and community settings. *BMJ.* 2012;345:e5205.
149. Roland M, Paddison C. Better management of patients with multimorbidity. *BMJ.* 2013;346:f2510.
150. Anderson G, Hopkins J. The latest disease burden challenge: People with multiple chronic conditions. In: *Health Reform: Meeting the Challenge of Ageing and Multiple Morbidities* [Internet]. Paris, France: OECD Publishing; 2011 [cited 2016 Aug 16]. p. 15–35. Available from: <http://www.oecd-ilibrary.org/content/chapter/9789264122314-4-en>
151. Wynand P, Van De Ven, Ellis RP. Chapter 14 - Risk Adjustment in Competitive Health Plan Markets. In: Newhouse AJC and JP, editor. *Handbook of Health Economics* [Internet]. Elsevier; 2000 [cited 2016 Aug 16]. p. 755–845. (*Handbook of Health Economics*; vol. 1, Part A). Available from: <http://www.sciencedirect.com/science/article/pii/S1574006400801730>
152. Lehnert T, König H-H. [Effects of multimorbidity on health care utilization and costs]. *Bundesgesundheitsblatt Gesundheitsforschung Gesundheitsschutz.* 2012 May;55(5):685–92.
153. Naessens JM, Stroebe RJ, Finnie DM, Shah ND, Wagie AE, Litchy WJ, et al. Effect of multiple chronic conditions among working-age adults. *Am J Manag Care.* 2011 Feb;17(2):118–22.
154. Yu W, Ravelo A, Wagner TH, Phibbs CS, Bhandari A, Chen S, et al. Prevalence and costs of chronic conditions in the VA health care system. *Med Care Res Rev MCRR.* 2003 Sep;60(3 Suppl):146S–167S.
155. Charlson M, Charlson RE, Briggs W, Hollenberg J. Can disease management target patients most likely to generate high costs? The impact of comorbidity. *J Gen Intern Med.* 2007 Apr;22(4):464–9.
156. Starfield B, Kinder K. Multimorbidity and its measurement. *Health Policy Amst Neth.* 2011 Nov;103(1):3–8.
157. Nuño Solinis R, Piñeira K. Strategy for tackling the challenge of chronicity Accessed 14 May 2013. [Internet]. *Health Policy Monitor*; 2010 [cited 2016 Aug 16]. Available from: <http://www.hpm.org/es/a16/1.pdf>.
158. Weiner JP, Dobson A, Maxwell SL, Coleman K, Starfield B, Anderson GF. Risk-adjusted Medicare capitation rates using ambulatory and inpatient diagnoses. *Health Care Financ Rev.* 1996;17(3):77–99.
159. O’Malley KJ, Cook KF, Price MD, Wildes KR, Hurdle JF, Ashton CM. Measuring diagnoses: ICD code accuracy. *Health Serv Res.* 2005 Oct;40(5 Pt 2):1620–39.

160. Majeed A. Sources, uses, strengths and limitations of data collected in primary care in England. *Health Stat Q Off Natl Stat.* 2004;(21):5–14.
161. Gorina Y, Kramarow EA. Identifying chronic conditions in Medicare claims data: evaluating the Chronic Condition Data Warehouse algorithm. *Health Serv Res.* 2011 Oct;46(5):1610–27.
162. Maio V, Yuen E, Rabinowitz C, Louis D, Jimbo M, Donatini A, et al. Using pharmacy data to identify those with chronic conditions in Emilia Romagna, Italy. *J Health Serv Res Policy.* 2005 Oct;10(4):232–8.
163. Wiréhn A-BE, Karlsson HM, Carstensen JM. Estimating disease prevalence using a population-based administrative healthcare database. *Scand J Public Health.* 2007;35(4):424–31.
164. Domínguez-Berjón MF, Borrell C, Cano-Serral G, Esnaola S, Nolasco A, Pasarín MI, et al. [Constructing a deprivation index based on census data in large Spanish cities(the MEDEA project)]. *Gac Sanit SESPAS.* 2008 Jun;22(3):179–87.
165. Basu A, Manning WG. Issues for the next generation of health care cost analyses. *Med Care.* 2009 Jul;47(7 Suppl 1):S109-114.
166. Basu A, Rathouz PJ. Estimating marginal and incremental effects on health outcomes using flexible link and variance function models. *Biostat Oxf Engl.* 2005 Jan;6(1):93–109.
167. Chen AY, Escarce JJ. Family structure and childhood obesity, Early Childhood Longitudinal Study - Kindergarten Cohort. *Prev Chronic Dis.* 2010 May;7(3):A50.
168. Fitzmaurice GM, Laird NM, Ware James H. *Applied longitudinal analysis.* 2nd ed. Wiley; 2011.
169. Ramsey S, Willke R, Briggs A, Brown R, Buxton M, Chawla A, et al. Good research practices for cost-effectiveness analysis alongside clinical trials: the ISPOR RCT-CEA Task Force report. *Value Health J Int Soc Pharmacoeconomics Outcomes Res.* 2005 Oct;8(5):521–33.
170. Martínez-Granado M, Greño P, Oleaga M. The Basque Country, Spain : Self - Evaluation Report [Internet]. 2012 [cited 2016 Aug 16]. (OECD Reviews of Higher Education in Regional and City Development). Available from: <http://www.oecd.org/edu/imhe/regionaldevelopment>
171. Gené-Badia J, Gallo P, Hernández-Quevedo C, García-Armesto S. Spanish health care cuts: penny wise and pound foolish? *Health Policy Amst Neth.* 2012 Jun;106(1):23–8.
172. Cabrera-León A, Jadad AR, Nuño-Solinís R, Bernabéu-Wittel M, Morales-Asencio JM, Valdivieso-Martínez B, et al. Improving care for people living with chronic diseases: Innovative examples from Spain. *Int J Healthc Manag.* 2012 Oct 1;5(4):208–15.
173. Lewis GH. “Impactibility models”: identifying the subgroup of high-risk patients most amenable to hospital-avoidance programs. *Milbank Q.* 2010 Jun;88(2):240–55.
174. Orueta JF, Nuño-Solinis R, Mateos M, Vergara I, Grandes G, Esnaola S. Predictive risk modelling in the Spanish population: a cross-sectional study. *BMC Health Serv Res.* 2013;13:269.

175. Rakovski CC, Rosen AK, Wang F, Berlowitz DR. Predicting Elderly at Risk of Increased Future Healthcare Use: How Much Does Diagnostic Information Add to Prior Utilization? *Health Serv Outcomes Res Methodol.* 2002;3(3–4):267–77.
176. DeSalvo KB, Jones TM, Peabody J, McDonald J, Fihn S, Fan V, et al. Health care expenditure prediction with a single item, self-rated health measure. *Med Care.* 2009 Apr;47(4):440–7.
177. Verisk Health. DxCG Risk Analytics Solutions [Internet]. [cited 2016 Feb 19]. Available from: <https://www.veriskhealth.com/answers/population-answers/dxCG-risk-analytics>
178. Sicras-Mainar A, Navarro-Artieda R, Grupo de estudio ACG-BSA. [Validating the Adjusted Clinical Groups [ACG] case-mix system in a Spanish population setting: a multicenter study]. *Gac Sanit SESPAS.* 2009 Jun;23(3):228–31.
179. Behrend C, Buchner F, Happich M, Holle R, Reitmeir P, Wasem J. Risk-adjusted capitation payments: how well do principal inpatient diagnosis-based models work in the German situation? Results from a large data set. *Eur J Health Econ HEPAC Health Econ Prev Care.* 2007 Mar;8(1):31–9.
180. van Kleef RC, van Vliet RCJA. Improving risk equalization using multiple-year high cost as a health indicator. *Med Care.* 2012 Feb;50(2):140–4.
181. Arce Sauto R, Saenz de Ormijana A, Orueta JF, Gagnon M-P, Nuño-Solinís R. A qualitative study on clinicians' perceptions about the implementation of a population risk stratification tool in primary care practice of the Basque health service. *BMC Fam Pract.* 2014;15:150.
182. Thorlby R. Reclaiming a population health perspective: Future challenges for primary care [Internet]. Nuffield Trust; 2013 [cited 2016 Aug 16]. Available from: http://www.nuffieldtrust.org.uk/sites/files/nuffield/publication/130425_reclaiming-a-population-health-perspective.pdf
183. Kingston M. Initial Uses of the PRISM Risk Stratification Tool in CCM Demonstrator Sites: A qualitative study [Internet]. NHS Wales; 2010 [cited 2016 Aug 16]. (Chronic Conditions Management Demonstrators: Evaluation Report). Available from: <http://www.wales.nhs.uk/sitesplus/documents/829/CCM%20Demonstrator%20PRISM%20Report%20Aug10.pdf>
184. Sicras-Mainar A, Prados-Torres A, Navarro-Artieda R. [Primary care doctors' opinion on a risk adjustment system: adjusted clinical groups]. *Rev Peru Med Exp Salud Pública.* 2013 Apr;30(2):345–7.
185. Graham ID, Logan J. Innovations in knowledge transfer and continuity of care. *Can J Nurs Res Rev Can Rech En Sci Infirm.* 2004 Jun;36(2):89–103.
186. Logan J, Graham ID. Toward a Comprehensive Interdisciplinary Model of Health Care Research Use. *Sci Commun.* 1998 Dec 1;20(2):227–46.
187. Rycroft-Malone J, Kitson A, Harvey G, McCormack B, Seers K, Titchen A, et al. Ingredients for change: revisiting a conceptual framework. *Qual Saf Health Care.* 2002 Jun;11(2):174–80.

188. MacDermid JC, Graham ID. Knowledge translation: putting the “practice” in evidence-based practice. *Hand Clin.* 2009 Feb;25(1):125–143, viii.
189. Rogers EM. *Diffusion of Innovations*, 5th Edition. New York: Free Press; 2003.
190. Braun V, Clarke V. Using thematic analysis in psychology. *Qual Res Psychol.* 2006 Jan;3(2):77–101.
191. Coulter A, Ellins J. Effectiveness of strategies for informing, educating, and involving patients. *BMJ.* 2007 Jul 7;335(7609):24–7.
192. Shadmi E, Freund T. Targeting patients for multimorbid care management interventions: the case for equity in high-risk patient identification. *Int J Equity Health.* 2013;12:70.
193. Wu RR, Orlando LA, Himmel TL, Buchanan AH, Powell KP, Hauser ER, et al. Patient and primary care provider experience using a family health history collection, risk stratification, and clinical decision support tool: a type 2 hybrid controlled implementation-effectiveness trial. *BMC Fam Pract.* 2013;14:111.
194. HCUP Chronic Condition Indicator (CCI). Healthcare Cost and Utilization Project (HCUP). 2009. Agency for Healthcare Research and Quality, Rockville, MD. <http://www.hcup-us.ahrq.gov/toolssoftware/chronic/chronic.jsp>. Accessed March 26, 2014.
195. HCUP Clinical Classifications Software (CCS) for ICD-9-CM. Healthcare Cost and Utilization Project (HCUP). 2006-2009. Agency for Healthcare Research and Quality, Rockville, MD. www.hcup-us.ahrq.gov/toolssoftware/ccs/ccs.jsp. Accessed July 11, 2013.
196. Quan H, Sundararajan V, Halfon P, Fong A, Burnand B, Luthi J-C, et al. Coding algorithms for defining comorbidities in ICD-9-CM and ICD-10 administrative data. *Med Care.* 2005 Nov;43(11):1130–9.
197. Quan H, Li B, Couris CM, Fushimi K, Graham P, Hider P, et al. Updating and validating the Charlson comorbidity index and score for risk adjustment in hospital discharge abstracts using data from 6 countries. *Am J Epidemiol.* 2011 Mar 15;173(6):676–82.
198. Estrategia de Atención a Pacientes con Enfermedades Crónicas en la Comunidad de Madrid [Internet]. Consejería de Sanidad. Comunidad de Madrid; 2013 [cited 2016 Jul 28]. Available from: <http://www.asociacionasaco.es/wp-content/uploads/2014/03/Estrategia-de-pacientes-chronicos-comunidad-de-madrid-ASACO-cancer-ovario-marzo-2014-texto.pdf>
199. Estrategia para el Abordaje de la Cronicidad en el Sistema Nacional de Salud [Internet]. Ministerio de Sanidad, Servicios Sociales e Igualdad; 2012 [cited 2016 Jul 28]. Available from: http://www.msssi.gob.es/organizacion/sns/planCalidadSNS/pdf/ESTRATEGIA_ABORDAJE_CRONICIDAD.pdf
200. Osasuna, Pertsonen Eskubidea, Guztion Ardura - Políticas de Salud para Euskad 2013 - 2020 [Internet]. Vitoria - Gasteiz: Departamento de Salud. Gobierno Vasco; 2014 [cited 2016 Jul 29]. Available from: http://www.osakidetza.euskadi.eus/contenidos/informacion/publicaciones_informes_estudio/es_pub/adjuntos/plan_salud_2013_2020.pdf

201. Líneas Estratégicas y Planes de Acción 2013-2016 [Internet]. Vitoria-Gasteiz: Osakidetza; 2013 Jun [cited 2016 Jul 29]. Available from: http://www.osakidetza.euskadi.eus/contenidos/informacion/osk_publicaciones/es_publi/adjuntos/estrategia/lineasEstrategicasOsakidetza.pdf
202. Plan de Intervención Poblacional. Gestión de Caso: Paciente Pluripatológico. Gestión de Enfermedad: Diabetes – EPOC - Insuficiencia Cardíaca. Protocolo de Intervención [Internet]. Comarca Araba. HU Araba. Osakidetza; 2012 Jun [cited 2016 Jul 29]. Available from: http://www.osakidetza.euskadi.eus/contenidos/informacion/premios_osakidetza/es_osk/adjuntos/04/321.pdf
203. Rosen A, Christiansen C, Montez M, et al. Evaluating Risk-Adjustment Methodologies for Patients With Mental Health and Substance Abuse Disorders in the Veterans Health Administration. *International Journal of HealthCare Technology and Management*. 2005;1/2(7):43–63.
204. Lamers LM. Risk-adjusted capitation based on the Diagnostic Cost Group Model: an empirical evaluation with health survey information. *Health Serv Res*. 1999 Feb;33(6):1727–44.
205. Newhouse JP, Manning WG, Keeler EB, Sloss EM. Adjusting capitation rates using objective health measures and prior utilization. *Health Care Financ Rev*. 1989;10(3):41–54.
206. Kansagara D, Englander H, Salanitro A, Kagen D, Theobald C, Freeman M, et al. Risk prediction models for hospital readmission: a systematic review. *JAMA*. 2011 Oct 19;306(15):1688–98.
207. Panattoni LE, Vaithianathan R, Ashton T, Lewis GH. Predictive risk modelling in health: options for New Zealand and Australia. *Aust Health Rev Publ Aust Hosp Assoc*. 2011 Feb;35(1):45–51.
208. Knutson D, Bella M, Llanos K. Predictive Modeling: A Guide for State Medicaid Purchasers [Internet]. Hamilton, NJ: Center for Healthcare Strategies, Inc.; 2009 Aug [cited 2016 Apr 16]. Available from: http://www.chcs.org/media/Predictive_Modeling_Guide.pdf
209. Winkelman R, Mehmud S. A Comparative Analysis of Claims-Based Tools for Health Risk Assessment [Internet]. Schaumburg, IL: Society of Actuaries; 2007 Apr [cited 2016 Feb 19]. Available from: <http://www.soa.org/Files/Research/Projects/risk-assessmentc.pdf>
210. Lix L, Yogendran M, Burchill C, Metge C, McKeen N, Moore D, et al. Defining and Validating Chronic Diseases: An Administrative Data Approach [Internet]. Winnipeg: Manitoba Centre for Health Policy; 2006 Jul [cited 2016 Apr 30] p. 217. Available from: <http://mchp-appserv.cpe.umanitoba.ca/reference/chronic.disease.pdf>
211. Riley GF. Administrative and claims records as sources of health care cost data. *Med Care*. 2009 Jul;47(7 Suppl 1):S51-55.
212. Frogner BK, Anderson GF, Cohen RA, Abrams C. Incorporating new research into Medicare risk adjustment. *Med Care*. 2011 Mar;49(3):295–300.

