

קוונטיזציה סקלרית ווקטורית תחת שגיאות-ערוץ

מאת

גל בן-דוד

לא להשאלה

קוונטיזציה סקלרית ווקטורית תחת שגיאות-ערוץ

חיבור על מחקר
לשם מילוי חלקי של הדרישות לקבלת תואר
דוקטור למדעים

מאת

גל בן-דוד

2164788

1



000004870807



הטכניון מכון טכנולוגי לישראל

הוגש לסנט הטכניון - מכון טכנולוגי לישראל

יוני 1995

חיפה

סיוון תשנ"ה

המחקר נערך בהנחייתו של פרופסור דוד מלאך
בפקולטה להנדסת חשמל.

תודתי העמוקה נתונה לפרופ' דוד מלאך על הצעת
הנושא, הכוונתו והנחייתו המסורה.

חיבור זה מהווה סיום של תקופה נהדרת, שהחלה עוד
בביה"ס התיכון, בה רכשתי את השכלתי המקצועית
במעבדה לעיבוד אותות.
תודתי העמוקה נתונה ליורם אור-חן על הפרויקט
הראשון במעבדה ועל התמיכה לאורך השנים.
תודה כמובן גם לזיוה, נמרוד, אורי, אבי ותמרה על
התקופה הנהדרת.

ברצוני להודות לקרן וולף על התמיכה הכספית הנדיבה
במסגרת המלגה לזכרו של ד"ר משה גלבע ז"ל.

לרנטה ודן-אילן היקרים

תוכן העניינים

עמוד

1	תקציר
3	רשימת סמלים וקיצורים
6	פרק 1 - מבוא
6	1.1 - תיאור הנושא
7	1.2 - מטרות העבודה ותוצאות עיקריות
8	1.3 - מבנה העבודה
9	פרק 2 - רקע וסקר ספרות
9	2.1 - קוונטיזציה וקטורית - מבוא
11	2.1.1 - התנאים לאופטימליות של קוונטיזציה וקטורית - תכן הקוונטיזציה
13	2.1.2 - תכן קוונטיזציה וקטורית לפי Kohonen
14	2.2 - קוונטיזציה וקטורית תחת שגיאות ערוץ
19	2.3 - הקטנת עיוות הערוץ ע"י שיבוץ אינדקסים
19	2.3.1 - שיבוץ אינדקסים ע"י אלגוריתם החלפת זוגות
20	2.3.2 - שיבוץ אינדקסים ע"י אלגוריתם Simulated Annealing
21	2.4 - שינוי תאי החלוקה וקטורית הייצוג
21	2.4.1 - קוונטיזציה וקטורית סקלרית
22	2.4.2 - קוונטיזציה וקטורית וקטורית
23	2.4.3 - תכן קוונטיזציה וקטורית לפי Kohonen
24	2.5 - תכן משולב של מבנה הקוונטיזציה ושיבוץ האינדקסים
26	פרק 3 - חסמים על עיוות הערוץ מעל כל המקורות האפשריים
26	3.1 - מבוא
26	3.2 - חסמי ביצועים מעל כל המקורות האפשריים
30	3.3 - שיפור החסמים ע"י שימוש במומנטים
31	3.3.1 - שיפור החסמים ע"י שימוש בהגבלת הספק
33	3.4 - חסימת עיוות הערוץ עבור קצבי שגיאות קטנים
36	3.5 - הקוונטיזציה וקטורית הסקלרית האחד עם הקוד הבינארי הטבעי תחת ערוץ בינארי סימטרי
40	3.6 - סיכום

תוכן העניינים (המשך)

<u>עמוד</u>	
41	פרק 4 - כיווץ ליניארי של קוונטיזרים וקטוריים להקטנת העיוות בתנאי שגיאות ערוץ
41	4.1 - מבוא
41	4.2 - תיאור הכיווץ הליניארי בקוונטיזר וקטורי
44	4.3 - קוונטיזר וקטורי עם כיווץ ליניארי (Scaled Vector Quantizer)
46	4.3.1 - קוונטיזר סקלרי עם כיווץ ליניארי
47	4.4 - דוגמאות מספריות
47	4.4.1 - קוונטיזר סקלרי מותאם לפילוג לפלס
49	4.4.2 - קוונטיזר סקלרי מותאם לפילוג גאומטרי מוכלל
51	4.4.3 - קוונטיזר וקטורי מותאם לפילוג גאומטרי
52	4.5 - סיכום
53	פרק 5 - האופטימליות של הקוד-הבינארי-הטבעי עבור קוונטיזר סקלרי אחיד ומקור אחיד (תחת ערוץ בינארי סימטרי)
53	5.1 - מבוא
53	5.2 - השוואה לקוד גריי (Gray)
56	5.3 - תקציר ההוכחה
56	5.3.1 - תיאור הבעיה ומעבר לרצף
58	5.3.2 - פתרון בעיית האופטימיזציה באמצעות כופלי לגרנז'
60	5.3.3 - הוכחת התלכדות ביצועי הקוד הבינארי הטבעי עם החסם התחתון
61	5.4 - סיכום
62	פרק 6 - חסמים על עיוות הערוץ מעל כל שיבוצי הקודים האפשריים (ערוץ סימטרי חסר זיכרון)
62	6.1 - מבוא
62	6.2 - תקציר פיתוח החסמים
63	6.2.1 - תיאור הבעיה
63	6.2.2 - שינוי במטריצת המרחקים המשוקללת
65	6.2.3 - מעבר לבעיית אופטימיזציה רציפה
66	6.2.4 - פתרון בעיית אופטימיזציה רציפה
68	6.3 - דוגמאות מספריות
68	6.3.1 - קוונטיזר סקלרי אחיד ומקור אחיד תחת ערוץ בינארי סימטרי
70	6.3.2 - קוונטיזר סקלרי אחיד ומקור אחיד תחת ערוץ בינארי סימטרי עם קוד Hamming (7,4) לתיקון שגיאות
71	6.3.3 - קוונטיזר אחיד מותאם למקור גאומטרי תחת ערוץ בינארי סימטרי
73	6.3.4 - קוונטיזר אחיד מותאם למקור גאומטרי תחת ערוץ בינארי סימטרי עם קוד Hamming (7,4) לתיקון שגיאות
74	6.3.5 - קוונטיזר וקטורי מותאם למקור גאומטרי תחת ערוץ בינארי סימטרי
75	6.4 - סיכום

תוכן העניינים (המשך)

<u>עמוד</u>	
76	פרק 7 - אלגוריתם תת-אופטימלי למציאת שיבוץ אינדקסים עבור ערוץ סימטרי חסר זיכרון
76	7.1 - מבוא
76	7.2 - תקציר פיתוח האלגוריתם
79	7.3 - שימוש באלגוריתם למקרים אסימפטוטיים
80	7.4 - סיכום
81	פרק 8 - סיכום, מסקנות והצעות להמשך מחקר
81	8.1 - סיכום
82	8.2 - הצעות להמשך מחקר
84	מקורות ספרות
87	נספח א' - תכונות מטריצת המרחקים של הקוונטייזר הסקלרי האחיד
90	נספח ב' - האופטימליות של הקוד הבינארי הטבעי עבור קוונטייזר סקלרי אחיד, מקור אחיד ותחת הערוץ הבינארי הסימטרי
100	נספח ג' - חסמים על עיוות הערוץ מעל כל השיבוצים האפשריים עבור ערוצים סימטריים חסרי-זיכרון
112	נספח ד' - האופטימליות של הקוד הבינארי הטבעי עבור קוונטייזר סקלרי אחיד, מקור אחיד ותחת הערוץ הבינארי הסימטרי עם קוד Hamming (7,4) לתיקון שגיאות
118	נספח ה' - אלגוריתם לשיבוץ תת-אופטימלי של אינדקסים בקוונטייזר וקטורי עבור ערוצים סימטריים חסרי-זיכרון
123	נספח ו' - תכונות ליניארי - הגדרות ותוצאות עיקריות

תקציר

למערכות קוונטיזציה וקטורית (וקוונטיזציה סקלרית כמקרה פרטי) קיים שימוש נרחב ביישומים של קידוד מקור. ניתן למצוא מערכות קוונטיזציה וקטורית רבות ביישומים של קידוד דיבור ותמונה. קוונטיזציה וקטורית מחלק את קבוצת כל האותות (הוקטורים) האפשריים למספר סופי של תאי-חלוקה, כאשר כל תא חלוקה מיוצג ע"י וקטור ייצוג. קוונטיזציה וקטורית מהווה לכן שיטה לדחיסה עם עיוות. כלומר, בתהליך אובד חלק מן המידע הקיים באות והשחזור שלו איננו זהה למקור. ההבדל בין האות המשוחזר לאות המקורי נקרא עיוות הקוונטיזציה.

מערכת תקשורת המבוססת על קוונטיזציה וקטורית בנויה משני חלקים: מקודד ומפענת. המקודד (לפני הכניסה לערוץ) בודק לאיזה תא חלוקה שייך הוקטור אותו עליו לקודד. גם במקודד וגם במפענת קיימת טבלה של וקטורי הייצוג, כאשר לכל וקטור ייצוג משובץ אינדקס ספרתי. האינדקס הספרתי משודר בערוץ והמפענת משחזר את וקטור הייצוג מן הטבלה.

תכן קוונטיזציה וקטורית מבוסס על ידיעת הסטטיסטיקה של מקור האות, כאשר מעשית נעשה התכן על סמך סדרת אימון שנדגמה במוצא מקור האות. שיטות הניתוח והתכן "הקלסיות" של מערכות קוונטיזציה מניחות כי אף על פי שהמידע הספרתי עובר בערוץ תקשורת, לא נגרמים שיבושים בתהליך העברתו. בערוצי תקשורת מעשיים נעשה שימוש בקידוד-ערוץ אשר במקרים רבים מביא את השפעת שגיאות הערוץ להיות זניחה.

במקרים רבים אחרים השפעת שגיאות הערוץ איננה זניחה, ושימוש בקוונטיזציה אשר לוקחים בחשבון את השגיאות בערוץ יביאו לביצועים טובים יותר.

אחת המטרות של עבודה זו היא לבחון את השפעת שגיאות הערוץ על ביצועי מערכות קוונטיזציה וקטורית נתונות. השגיאות בערוץ התקשורת גורמות לאינדקס שגוי להופיע במפענת, אשר יפוענח לוקטור שחזור שגוי. המרחק בין הוקטור שנתקבל לוקטור שאמור היה להתקבל במוצא המפענת נקרא עיוות הערוץ. המרחק בין הוקטור (השגוי) שנתקבל לאות המקורי נקרא העיוות הכולל. בעבודה זו אנו מניחים כי ערוץ התקשורת הינו חסר-זיכרון, כאשר חלק מן התוצאות נתקבלו, בפרט, עבור הערוץ הבינארי הסימטרי.

בנוסף למציאת חסמים על ביצועי מערכות קוונטיזציה וקטורית נתונות, העבודה מתרכזת בשני גורמים המשפיעים על עיוות הערוץ ונתונים בידי המתכנן. הגורם הראשון הוא מבנה הקוונטיזציה וקטורית (והסקלרית) מבחינת תאי חלוקה ווקטורי ייצוג. הגורם השני הוא שיבוץ האינדקסים המשודרים בערוץ לוקטורי הייצוג.

בחלקה הראשון של העבודה מפותחים חסמים על עיוות הערוץ מעל כל מקורות האות האפשריים. חסמים אלו מספקים למתכנן מידע כמותי על עיוות הערוץ. מוצגות מספר דוגמאות מספריות להדגמת החסמים. עבור המקרה המיוחד של קוונטיזציה וקטורית סקלרית אחיד, קוד בינארי טבעי וערוץ בינארי סימטרי, החסם העליון מתלכד מעשית עם החסם התחתון. בנוסף, עיוות הערוץ עבור המקרה הזה איננו תלוי מעשית במספר הסיביות של הקוונטיזציה. בדוגמאות אחרות, המרווח בין החסם העליון לחסם התחתון הוא גדול יחסית וידעתם איננה תורמת מספיק להערכת ביצועי המערכת. עבור מקרים אלו מוצגים חסמים הדוקים יותר עבור משפחה מצומצמת יותר של מקורות, המאופיינת ע"י מומנטים של הסתברות המקור ובפרט אילוץ על

הספק המקור. כמו-כן מוצגים חסמים אסימפטוטיים עבור ערוץ בינארי סימטרי (בלי או עם קוד לתיקון שגיאות) כאשר הסתברות השגיאה בערוץ שואפת לאפס.

עבור קוונטייזר סקלרי אחיד בן 4 סיביות ויותר, עיוות הערוץ עבור השיבוץ הבינארי הטבעי קטן יותר מאשר ממוצע העיוות מעל כל השיבוצים האפשריים, עבור כל מקור שהוא.

בעבודות קודמות שנעשו בנושא הוצגו תנאים הכרחיים לאופטימליות של קוונטייזר וקטורי בתנאי שגיאות ערוץ. תנאים אלו מביאים לתהליך תכן מסובך, אשר מניב ספרייה של קוונטיזרים שונים, שכל אחד מהם מתאים לתנאי ערוץ שונים. שמירת ספרייה כזו במפענח ובמקודד עולה בדרישות זיכרון יקרות. בעבודה זו אנו מציעים שיטה תת-אופטימלית הדורשת רק כיווץ ליניארי של תאי-החלוקה וקטורי הייצוג בתלות בשגיאות הערוץ. תהליך התכן פשוט הרבה יותר, ומזדהה ברובו עם התכן ה-"קלסי" שלא מתחשב בשגיאות ערוץ. גם הדרישות על הזיכרון במערכת קטנות בהרבה. בעבודה מוצגות דוגמאות מספריות המראות שהתשלום בביצועים, יחסית לקוונטייזר המתוכנן לפי התנאים לאופטימליות, הוא נמוך.

גורם חשוב המשפיע על עיוות הערוץ הוא שיבוץ האינדקסים לוקטורי הייצוג. כללית, המטרה היא לגרום לשגיאות ערוץ לגרום לנזק הקטן ביותר האפשרי. ישנו מספר עצום של שיבוצים אפשריים (לקוונטייזר בעל N וקטורי ייצוג יש $N!$ שיבוצים אפשריים) שבד"כ אינו מאפשר מעשית את הבדיקה של כולם.

עבור המקרה המיוחד של קוונטייזר סקלרי אחיד המוזן ממקור אחיד, ניתנת הוכחה כי השיבוץ הבינארי הטבעי הוא שיבוץ אופטימלי, המביא לעיוות הערוץ הקטן ביותר.

בהמשך מפותחים חסמים על עיוות הערוץ, מעל כל השיבוצים האפשריים, עבור ערוצים חסרי-זיכרון כלשהם. מוצגות דוגמאות מספריות המשוות את החסמים עם כעשרת אלפים שיבוצים שנבחרו באקראי.

בחלקה האחרון של העבודה מפותח אלגוריתם לשיבוץ תת-אופטימלי של אינדקסים לוקטורי הייצוג בקוונטייזר וקטורי, הפועל תחת ערוץ סימטרי חסר זיכרון. אנו מראים כי מימוש האלגוריתם הוא בסיבוכיות של $O(N^3)$.

בדוגמאות מספריות, הביצועים המתקבלים מן האלגוריתם טובים מן הביצועים המתקבלים מאלגוריתם תת-אופטימלי נפוץ בספרות של חילופי אינדקסים, שהוא בסיבוכיות $O(N^4)$.

בנוסף, מוצגת גם השוואה בין החסמים על עיוות הערוץ מעל כל השיבוצים האפשריים לבין חיפוש בעשרת אלפים שיבוצים אקראיים ועבור שני מקרים נערכת השוואה גם עם השיבוץ התת-אופטימלי המוצע. מן ההשוואות עולה כי החיפוש האקראי איננו מביא לתוצאות מספקות בגלל העושר הרב של שיבוצים אפשריים (עבור קוונטייזר של 4 סיביות בלבד קיימים $2 \cdot 10^{13}$ שיבוצים אפשריים). עבור המקרה המיוחד של קוונטייזר סקלרי אחיד ומקור אחיד, מתלכד השיבוץ המוצע עם החסם התחתון. במקרה טיפוסי שנבדק בסימולציה, נמוך עיוות הערוץ עבור השיבוץ המוצע ב-8dB בהשוואה לממוצע של עיוות הערוץ מעל כל השיבוצים האפשריים. עבור אותו מקרה, העיוות כתוצאה מאלגוריתם חילופי האינדקסים גבוה ב-1dB מן העיוות עבור השיבוץ המתקבל מן האלגוריתם המוצע.

רשימת סמלים וקיצורים

- $[x]$ - הערך השלם של x
- δ_{ij} - דלתה של Kronecker
- K - מימד הוקטורים אותם מקודד הקוונטיזר הוקטורי
- N - מספר וקטורים/רמות הייצוג של קוונטיזר וקטור/סקלרי
- L - מספר הסיביות של קוונטיזר וקטור/סקלרי
- L^0 - החזקה הדומיננטית של שגיאות הערוץ בערוץ בינארי סימטרי
- R^Q - קצב פליטת המידע במוצא המקודד (בסיביות לדגימה)
- R_i - תא/אינטרוול החלוקה ה- i בקוונטיזר וקטור/סקלרי
- f_x - צפיפות ההסתברות של המשתנה האקראי הוקטורי \underline{x}
- Q - אופרטור הקוונטיזר הוקטורי (כולל מקודד ומפענח)
- \mathcal{E} - אופרטור הקידוד
- \mathcal{D} - אופרטור הפיענוח
- D_{Total} - עיוות כולל בקוונטיזר וקטור/סקלרי
- D_Q - עיוות הקוונטיזציה בקוונטיזר וקטור/סקלרי
- D_c - עיוות הערוץ בקוונטיזר וקטור/סקלרי
- \bar{D}_c - ממוצע עיוות הערוץ בקוונטיזר וקטור/סקלרי על פני כל השיבוצים האפשריים
- 0 - וקטור N -מימדי המורכב כולו מאפסים
- $\underline{1}$ - וקטור N -מימדי המורכב כולו מאחדים
- ρ - וקטור רמות הייצוג בקוונטיזר סקלרי אחד
- ρ_i - רמת הייצוג ה- i בקוונטיזר סקלרי אחד
- s_i - אות בערוץ תקשורת
- \underline{z} - וקטור כללי N -מימדי
- C_i - מטריצה המכילה אחדים בעמודה ה- i והיתר אפסים

- ϕ_i - וקטור הייצוג ה- i של קוונטיזר וקטורי
- $d(\cdot, \cdot)$ - מידת מרחק בין וקטורים
- D - מטריצת המרחקים בין וקטורי הייצוג של קוונטיזר וקטורי/סקלרי
- \hat{D} - מטריצת מרחקים משוקללת בין וקטורי הייצוג של קוונטיזר וקטורי/סקלרי
- \bar{D} - מטריצת מרחקים משוקללת מנורמלת
- Z - מטריצה יוניטרית המכילה את הוקטורים העצמיים של המטריצה \bar{D}
- z_i - הוקטור העצמי ה- i של המטריצה \bar{D}
- Ω - מטריצה אלכסונית המכילה את הערכים העצמיים של המטריצה \bar{D}
- ω_i - הערך העצמי ה- i של המטריצה \bar{D}
- S_i - סכום האיברים בשורה ה- i של מטריצת מרחקים משוקללת
- S - סכום משתני עזר הנוספים למטריצת מרחקים משוקללת
- Δ - מרחק בין רמות ייצוג שכנות בקוונטיזר סקלרי אחיד
- P - מטריצה אלכסונית המכילה את הסתברויות המקור
- Q - מטריצת הסתברויות הערוץ
- Q_N - מטריצת הסתברויות הערוץ במקרה של ערוץ בינארי סימטרי ו- N סיביות
- Q_H - מטריצת הסתברויות הערוץ עבור ערוץ בינארי סימטרי עם קוד Hamming לתיקון שגיאות
- $c(i)$ - מלת הקוד ה- i עבור קוד לתיקון שגיאות
- $H(i, j)$ - מרחק Hamming בין הייצוגים הבינאריים של המספרים i ו- j
- q - הסתברות שגיאה בערוץ בינארי סימטרי
- V - מטריצה יוניטרית המכילה את הוקטורים העצמיים של מטריצת הערוץ Q
- v_i - הוקטור העצמי ה- i של מטריצת הערוץ Q
- U - מטריצה יוניטרית שעמודתה הראשונה היא $\underline{1}$
- Λ - מטריצה אלכסונית המכילה את הערכים העצמיים של מטריצת הערוץ Q
- λ_i - הערך העצמי ה- i של מטריצת הערוץ Q
- Π - אופרטור פרמוטציה

π - מטריצת פרמוטציה

$L(\cdot)$ - אופרטור לגרנג'י

μ_i - כופל לגרנג'י ה- i

BER - Bit Error Rate

BSC - Binary Symmetric Channel

COVQ - Channel Optimized Vector Quantizer

LP - Linear Programming

LPC - Linear Predictive Coding

NBC - Natural Binary Code

NVQ - Noiseless Vector Quantizer

PDF - Probability Density Function

QA - Quadratic Assignment

RVQ - Robust Vector Quantizer

SA - Simulated Annealing

SQ - Scalar Quantizer

SVQ - Scaled Vector Quantizer

VAPC - Vector Adaptive Predictive Coding


VQ - Vector Quantizer

פרק 1 - מבוא

1.1 תיאור הנושא

עבודת מחקר זו עוסקת בחקר הביצועים של מערכות קידוד מסוג קוונטיזציה וקטורית כאשר המידע הספרתי מועבר דרך ערוצי תקשורת רועשים. בנוסף מוצעות במחקר דרכים לשיפור הביצועים של מערכות אלו.

מטרתן של מערכות קוונטיזציה וקטורית (VQ - Vector Quantization) וקוונטיזציה סקלרית (SQ - Scalar Quantization) היא ייצוג אותות אנלוגיים בצורה ספרתית בנאמנות הגבוהה ביותר שניתן להשיג במגבלות קצב (בסיביות לדגימה) וסיבוכיות (בפעולות חישוביות לדגימה). את המידע הספרתי ניתן לשדר דרך ערוצים ספרתיים. דוגמאות רבות לשימוש בקוונטיזציה וקטורית וסקלרית לקידוד אותות דיבור ותמונות ניתן למצוא ב-[Ge92] וב-[Ja84]. בציור 1.1 מתוארת באופן סכימטי מערכת תקשורת מבוססת VQ.



ציור 1.1 - מערכת קוונטיזציה וקטורית

Fig. 1.1 - Vector Quantization System

מערכת התקשורת מורכבת ממקודד (Encoder) ומפענח (Decoder). המקודד מקבל בזמן t ממקור האות (Source) וקטור $\underline{x}(t)$ של K דגימות אותו על המערכת לקודד, ולהעביר ליעד (Destination) דרך ערוץ ספרתי (Channel). עבור המקרה הפרטי $K = 1$, מערכת הקידוד נקראת קוונטיזציה סקלרית - SQ. מערכת ה-VQ מקודדת את וקטור הכניסה למלת קוד (Codeword) ספרתית $y(t)$ המשודרת בערוץ.

מלת הקוד הספרתית $y(t)$ נבחרת מתוך אלפבית הערוץ (Channel Alphabet) הכולל מספר סופי של ערכים אפשריים. הערוץ איננו מושלם ולעתים קורות בו שגיאות. מסיבה זו המידע הספרתי במוצא הערוץ $\hat{y}(t)$ איננו זהה לחלוטין למידע הנכנס אליו. המפענח מקבל את המידע במוצא הערוץ ומפיק וקטור ייצוג/שחזור $\hat{\underline{x}}(t)$ (Representation/Reconstruction Vector) בן K דגימות המתאים ל- $\hat{y}(t)$ מתוך טבלת וקטורי הייצוג (Codebook). וקטור הייצוג מסופק ליעד (Destination).

גם מימוש המקודד נעשה לרוב בעזרת אותה טבלת וקטורי ייצוג. עם קבלת וקטור $\underline{x}(t)$ לקידוד, המקודד עורך חיפוש בין וקטורי הייצוג למציאת המועמד הקרוב ביותר אליו (לפי תנאי השכן הקרוב שיתואר בפרק 2).

כאמור, בערוץ משודר אינדקס ספרתי המצביע על וקטור ייצוג. בנוכחות שגיאות ערוץ ישנה חשיבות באיזה שיבוץ אינדקסים ספציפי נעשה שימוש. אין אפשרות להעביר את הוקטור $\underline{x}(t)$ במדויק ליעד משתי סיבות עיקריות:

א. האות הפיזיקלי המקורי הוא לרוב אות אנלוגי בעל רצף של ערכים אפשריים. הערוץ הספרתי מסוגל להעביר ערכים מתוך אלפבית הערוץ שמספרם סופי. המפענח יפיק לכן מספר סופי של וקטורי שחזור אפשריים. ולכן, גם עבור ערוץ מושלם (שעבורו המוצא הספרתי זהה לכניסה $\hat{y}(t) = y(t)$ בכל עת) קיים עיוות בין וקטור הכניסה לוקטור היציאה. עיוות זה נקרא **עיוות הקוונטיזציה** (Quantization Distortion).

במציאות נדגם האות ע"י ממיר אנלוגי לספרתי סקלרי כשלב ראשון (Analog to Digital Conversion) והמידע הנכנס למקודד הוא ספרתי. במקרה זה עיוות הקוונטיזציה נובע מן השימוש ב-VQ (או SQ) לדחיסת המידע. מספר הערכים האפשריים בוקטור הכניסה למקודד גדול ממספר הערכים האפשריים באלפבית הערוץ.

ב. שגיאה בערוץ תגרום לכך שהמפענח יספק ליעד וקטור שחזור מוטעה. העיוות הנגרם כתוצאה משגיאה זו נקרא **עיוות הערוץ** (Channel Distortion).

עבודה רבה מדווחת בספרות בנושא של הקטנת עיוות הקוונטיזציה עבור ערוצים מושלמים (ללא עיוות ערוץ). דוגמאות והפניות למאמרים נתן למצוא בספרים [Ge92] ו-[Ja84]. עבודות רבות נוספות עוסקות במימוש יעיל של מערכות VQ, ללא עיוות ערוץ, הן בשלבי התכן והן במימוש. במקרים מעשיים כאשר קיים ערוץ לא-מושלם ניתן להוסיף קוד לתיקון שגיאות (Error Correcting Code). במקרים רבים, שימוש בקוד לתיקון שגיאות מספק למערכת הקוונטיזציה ערוץ שקול (הכולל מקודד ערוץ, ערוץ ומפענח ערוץ) עם הסתברויות שגיאה נמוכות מאד, כך שמעשית ניתן להזניח את עיוות הערוץ.

עבודה זו עוסקת באותם מקרים, שאף הם רבים, בהם, משיקולי מימוש, לא משתמשים בקוד לתיקון שגיאות או שהקוד איננו מספק ערוץ שקול עם הסתברויות שגיאה נמוכות מספיק. במקרים אלו, נוצרות שגיאות במידע הספרתי ועיוות הערוץ הוא גורם שיש להתחשב בו. הסעיף הבא מתאר את מטרות עבודת המחקר ואת תוצאותיה העיקריות ביתר פירוט.

1.2 מטרות העבודה ותוצאות עיקריות

מטרת עבודת מחקר זו היא חקר עיוות הערוץ ומציאת חסמים על גודלו במערכות קוונטיזציה סקלרית ווקטורית. מוצעות בעבודה גם מספר דרכים לשיפור הביצועים של קוונטיזציה סקלרית ווקטורית הפועלים תחת שגיאות ערוץ.

התוצאות העיקריות שהושגו בעבודה זו הן:

- א. על מנת לקבל מידע כמותי על עיוות הערוץ במערכות קיימות פותחו חסמים על עיוות הערוץ מעל כל מקורות האות האפשריים. העבודה מציגה דרך למציאת חסמים, עליון ותחתון, עבור ערוצים חסרי-זיכרון כלשהם. כמו-כן, מוצגים חסמים אסימפטוטיים עבור ערוץ בינארי סימטרי (בלי או עם קוד לתיקון שגיאות) כאשר הסתברות השגיאה בערוץ שואפת לאפס.
 - ב. עבודות רבות בספרות דנות בשינוי מבנה הקוונטיזר הוקטורי כך שביצועיו ישתפרו תחת שגיאות ערוץ. הפתרונות האופטימליים המוצעים הנם יקרים ומורכבים מבחינת התכן והמימוש. עבור הערוץ הבינארי הסימטרי, אנו מציעים שינוי פשוט במבנה הקוונטיזר המביא לשיפור (תת-אופטימלי) של הביצועים. שיטה זו הנה פשוטה לתכן וזולה למימוש, עם ביצועים הפחותיים אך במעט בהשוואה לאלגוריתמים האופטימליים.
 - ג. עיוות הערוץ תלוי במידה רבה בשיבוץ מילות הקוד לוקטורי הייצוג. בעבודה מוצגים חסמים על עיוות הערוץ מעל כל השיבוצים האפשריים של מילות קוד לערוצים חסרי זיכרון. חסמים אלו מאפשרים למתכנן להעריך את השפעת השיבוץ על המערכת שבתכנון.
 - ד. עבור ערוץ סימטרי חסר זיכרון מוצע אלגוריתם תת-אופטימלי לשיבוץ של מילות קוד לוקטורי הייצוג בקוונטיזר. האלגוריתם דורש פחות חישובים מאלגוריתם תת-אופטימלי אחר המקובל בספרות. בדוגמאות מספריות מניב האלגוריתם המוצע שיבוץ עדיף על האלגוריתם המקובל.
- בנוסף לכך, עבור המקרה המיוחד של קוונטיזר סקלרי אחיד ומקור אחיד ניתנת הוכחה כי הקוד הבינארי הטבעי הוא השיבוץ האופטימלי. בעבודה מוצגות תכונות נוספות של מקרה זה (גם בהקשר של סעיף א' לעיל).

1.3 מבנה העבודה

בפרק 2 ניתן רקע כללי ותיאור מערכות קוונטיזציה הפועלות תחת שגיאות ערוץ. כמו-כן נסקרים מקורות הספרות הדנים במערכות אלו ודרכים שהוצעו לשיפור ביצועי הקוונטיזרים תחת שגיאות ערוץ. פרק 3 עוסק בחסמים על עיוות הערוץ מעל כל מקורות האות האפשריים (סעיף א' לעיל). פרק 4 דן בכיווץ ליניארי של קוונטיזרים וקטורים לשיפור הביצועים תחת שגיאות ערוץ (סעיף ב'). פרק 5 דן בהוכחת האופטימליות של השיבוץ הבינארי הטבעי עבור קוונטיזר סקלרי אחיד ומקור אחיד (סעיף ד'). פרק 6 עוסק במציאת חסמים על עיוות הערוץ מעל כל השיבוצים האפשריים עבור ערוצים חסרי זיכרון (סעיף ג'). בפרק 7 מתואר האלגוריתם המוצע לשיבוץ של מילות הקוד (סעיף ד'). סיכום והצעות להמשך מחקר מופיעים בפרק 8.

פרק 2 - רקע וסקר ספרות

2.1 קוונטיזציה וקטורית - מבוא

קוונטיזציה וקטורית תופסת מקום נכבד במערכות קידוד מקור (Source Encoding) מודרניות. הקוונטיזציה הסקלרית, מקרה פרטי של הקוונטיזציה הווקטורית, שימושית עדיין במערכות רבות בזכות פשטות המימוש והתכן. בנוסף לכך, הקוונטיזציה הסקלרית רגישה פחות לחוסר התאמה בין המקור עבורו היא תוכננה למקור במציאות. דוגמאות רבות והפניות למאמרים העוסקים בקוונטיזציה וקטורית וסקלרית לקידוד אותות דיבור ותמונה נתן למצוא ב-[Ge92] וב-[Ja84]. המוטיבציה לשימוש בקוונטיזציה וקטורית נובעת מתורת האינפורמציה [Vi79]. עבור קצב שידור (Transmission Rate) נתון בערוץ R , העיוות (Distortion) המתקבל מקוונטיזציה וקטורית יהיה קטן יותר מהעיוות הנגרם ע"י קוונטיזציה סקלרית. קוונטיזציה וקטורית Q במימד K (Dimension) ובגודל N (Size) הוא מיון מהמרחב האוקלידי ה- K מימדי, \mathcal{X}^K , לקבוצה סופית C המכילה N איברים ϕ_i , $i = 0, 1, \dots, N-1$, המכונים וקטורי ייצוג או וקטורי שחזור (Representation/Reconstruction Vectors). וקטורי הייצוג הנם גם כן ב- \mathcal{X}^K . הקבוצה C מכונה ספר הקוד (Codebook).

$$Q: \mathcal{X}^K \rightarrow C = \{\underline{\phi}_0, \underline{\phi}_1, \dots, \underline{\phi}_{N-1}\} \quad (2.1)$$

השגיאה או העיוות הנוצר מפעולת הקוונטיזציה הינו המרחק בין וקטור הכניסה \underline{x} לוקטור הייצוג המתקבל:

$$d(\underline{x}, Q(\underline{x})) \quad (2.2)$$

$$R^Q = \frac{\log_2 N}{K} \quad \frac{\text{Bits}}{\text{Sample}} \quad \text{מוגדר ע"י: (Quantizer Rate)}$$

הקוונטיזציה מבצע חלוקה (Partition) של מרחב הכניסה \mathcal{X}^K ל- N תאי חלוקה (Cells) זרים. לכל וקטור ייצוג קיים תא חלוקה כך שכל הוקטורים בתא זה מיוצגים ע"י וקטור הייצוג. תא החלוקה ה- i :

$$R_i = \{\underline{x} \in \mathcal{X}^K : Q(\underline{x}) = \underline{\phi}_i\} \quad (2.3)$$

תאי החלוקה הנם זרים לזה לזה ומכסים יחדיו את כל המרחב:

$$\bigcup_i R_i = \mathcal{X}^K, \quad R_i \cap R_j = \emptyset \text{ for } i \neq j \quad (2.4)$$

תא-חלוקה יכול להיות חסום (Bounded) ואז הוא נקרא תא "גרגירי" (Granular Cell) או בלתי חסום ואז הוא נקרא תא "העמסה" (Overload Cell).


הגדרה: קוונטיזצור וקטורי נקרא רגולרי אם תאי החלוקה הנם קמורים (Convex) וכל וקטור ייצוג נמצא בתא אותו הוא מייצג - $\phi_i \in R_i \quad \forall i$. בהמשך נראה כי עבור מידת מרחק ריבועית, קוונטיזצור המקיים את תנאי האופטימליות לתכן קוונטיזצור ללא שגיאות ערוץ הוא רגולרי. תחת שגיאות ערוץ תכונה זו איננה מובטחת.

ניתן לפצל את פעולת הקוונטיזצור הוקטורי לשני רכיבים: המקודד (Encoder) והמפענח (Decoder). המקודד \mathcal{E} הוא מיפוי מוקטורי הכניסה לקבוצת אינדקסים $I = (0, 1, \dots, N-1)$ והמפענח \mathcal{D} הוא מיפוי מקבוצת האינדקסים לספר הקוד C .

$$\mathcal{E}: \mathcal{R}^k \rightarrow I \quad \text{and} \quad \mathcal{D}: I \rightarrow C \quad (2.5)$$

$$\mathcal{Q}(\underline{x}) = \mathcal{D}(\mathcal{E}(\underline{x}))$$

האינדקסים מן הקבוצה I הם המשודרים בערוץ. אין קביעה חד-משמעית של השיבוץ (Index Assignment) בין הוקטורים המייצגים לאינדקסים המתאימים להם וניתן לבצע $N!$ שיבוצים אפשריים. השיבוץ מתואר ע"י מטריצת פרמוטציה π , המכילה רק אפסים ואחדים וסכום כל שורה ועמודה שלה שווה לאחד. בצירור 2.1 מתואר סכמטית קוונטיזצור וקטורי רגולרי:



צירור 2.1 - תאור סכימטי של קוונטיזצור וקטורי רגולרי

Fig. 2.1 - Schematic drawing of a Regular Vector Quantizer

ניתן לראות בסכמה את אזורי החלוקה R_i , את וקטורי הייצוג $\underline{\phi}_i$ ואת האינדקס המותאם לכל וקטור ייצוג.

השיבוץ שנבחר בדוגמה הוא:

$$\left\{ \underline{\phi}_0, \underline{\phi}_1, \underline{\phi}_2, \underline{\phi}_3, \underline{\phi}_4, \underline{\phi}_5, \underline{\phi}_6, \underline{\phi}_7 \right\} \\ \{3, 5, 6, 7, 0, 4, 1, 2\} \quad (2.6)$$

לדוגמה, וקטור הכניסה המסומן ב- \underline{x} נכלל בתוך R_0 ולכן מיוצג ע"י $\underline{\phi}_0$ והאינדקס 3 ישודר בערוץ.

המרחק הממוצע בין וקטור הכניסה לקוונטייזר לוקטור היציאה (ללא שגיאות ערוץ), נקרא עיוות הקוונטיזציה (Quantization Error).

$$D_Q = E[d(\underline{x}, Q(\underline{x}))] = \\ = \int_{\mathbb{R}^K} d(\underline{x}, Q(\underline{x})) \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x} = \\ = \sum_{i=0}^{N-1} \int_{R_i} d(\underline{x}, \underline{\phi}_i) \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x} \quad (2.7)$$

2.1.1 התנאים לאופטימליות של קוונטייזר וקטורי - תכנון הקוונטייזר

מטרת התכנון של קוונטייזר וקטורי (ללא התחשבות בשגיאות ערוץ) היא מינימום של עיוות הקוונטיזציה. קיימים שני תנאים הכרחיים למינימום של העיוות [Ge92, סעיף 10.1]:

תנאי השכן הקרוב (Nearest Neighbor Condition)

בהינתן ספר קוד C , וקטור כניסה \underline{x} ישוחרר ע"י וקטור הייצוג הקרוב אליו ביותר:

$$Q(\underline{x}) = \underline{y}_i \text{ if } d(\underline{x}, \underline{\phi}_i) \leq d(\underline{x}, \underline{\phi}_j) \text{ for } j = 0, 1, \dots, N-1 \quad (2.8)$$

תנאי זה קובע את תאי החלוקה R_i , $i = 0, 1, \dots, N-1$. הבדיקה לאיזה תא שייך וקטור כניסה \underline{x} נעשית ע"י מדידת המרחק ממנו לכל וקטורי הייצוג ומציאת הקרוב אליו ביותר. בנוסף, עבור מידת מרחק אוקלידית, תנאי השכן הקרוב מביא לכך שתא חלוקה הוא חיתוך של חצאי-מרחב (Half Space) המתוארים ע"י על-מישורים (Hyperplane). תא חלוקה כזה הוא קמור (Convex).

תנאי הצנטרואיד (Centroid Condition)

בהינתן חלוקה המרחב לתאי חלוקה, וקטור ייצוג $\underline{\phi}_i$ המייצג תא חלוקה R_i הוא הוקטור המביא למינימום העיוות בתא זה:

$$\begin{aligned} Q(\underline{x}) &= \underline{\phi}_i \text{ for all } \underline{x} \in R_i \\ \text{if } E\{d(\underline{x}, \underline{\phi}_i) | \underline{x} \in R_i\} &\leq E\{d(\underline{x}, \underline{z}) | \underline{x} \in R_i\} \text{ for all } \underline{z} \in R_i \end{aligned} \quad (2.9)$$

עבור מידת מרחק ריבועית $d(\underline{x}, \underline{y}) = \|\underline{x} - \underline{y}\|^2$ תנאי הצנטרואיד מצטמצם לכדי:

$$\begin{aligned} Q(\underline{x}) &= \underline{\phi}_i \text{ for all } \underline{x} \in R_i \\ \text{if } \underline{\phi}_i &= E\{\underline{x} | \underline{x} \in R_i\} = \frac{\int_{R_i} \underline{x} \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x}}{\int_{R_i} f_{\underline{x}}(\underline{x}) \cdot d\underline{x}} \end{aligned} \quad (2.10)$$

תנאי זה מבטיח כי $\underline{\phi}_i \in R_i \quad \forall i$ וביחד עם תכונת הקמירות, מתאר קוונטייזר רגולרי. כאמור, תנאים אלו הם תנאים הכרחיים בלבד. תכן קוונטייזר וקטורי נעשה לרב בחישוב איטרטיבי המיישם את שני התנאים לסירוגין. אלגוריתם איטרטיבי כזה המבוסס על ידיעת צפיפות הסתברות של מקור האות $f_{\underline{x}}(\underline{x})$ נקרא אלגוריתם Lloyd והוא מתואר ב-[Li82]. במקרים מעשיים לא ידועה פונקצית ההסתברות, ואלגוריתם התכן מבוסס על סדרת אימון של וקטורים. אלגוריתם התכן במקרה זה נקרא LBG והוא מתואר ב-[Li80]. קיימות גרסות רבות לאלגוריתם ה-LBG שנועדו בעיקר להקטין את סיבוכיות החישוב בפעולת הקידוד. גרסה אחת כזו נקראת LBG במבנה עץ [Ge92 סעיף 12.4]. גישה זו נותנת ביצועים פחותים מבחינת עיוות קוונטיזציה בהשוואה ל-LBG רגיל, אך היא יעילה במספר חישובים במימוש. תכן ה-VQ במבנה עץ מבוסס על פיצול תאי החלוקה הקיימים בכל איטרציה כאשר הפיצול נעשה רק לפי וקטורי האימון השייכים לתא החלוקה.

אלגוריתם ה-LBG במבנה עץ [Ge92] סעיף 12.4

1. בנה קוונטייזר בן סיבית אחת עם שני תאי חלוקה $R_0^{(1)}, R_1^{(1)}$. הסימון העילי מסמן את מספר הסיביות בקוונטייזר $l \leftarrow 1$. קוונטייזר זה חילק את סדרת האימון לשתי תת-סדרות: וקטורי-אימון השייכים ל- $R_0^{(1)}$ ווקטורי-אימון השייכים ל- $R_1^{(1)}$.

2. פצל כל תא חלוקה לשני תתי-תאים: $R_i^{(l)}$ מפוצל ל- $R_{2i}^{(l+1)}, R_{2i+1}^{(l+1)}$, עבור $i = 0, 1, \dots, 2^l - 1$. בתהליך פיצול תא חלוקה נעשה שימוש רק בוקטורי-האימון השייכים לאותו תא חלוקה.

3. כעת הקוונטייזר הוא בעל סיבית נוספת $l+1 \leftarrow l$. אם הגעת למספר הסיביות הדרוש $l = L$ סיים, אחרת חזור לצעד 2.


שיבוץ האינדקסים ה"טבעיים" באלגוריתם זה הוא שאינדקס i ישובץ לתא החלוקה $R_i^{(L)}$ ולוקטור הייצוג $\underline{\phi}_i^{(L)}$ עבור $i = 0, 1, \dots, 2^l - 1$

2.1.2 תכן קוונטייזר וקטורי לפי Kohonen

גישה אחרת לתכן קוונטייזר וקטורי היא לפי Kohonen [Ko90], וידועה בשם Self-Organizing Map. תהליך התכן הוא איטרטיבי ומבוסס גם כן על סדרת אימון. בשלב ראשון בונים, על סמך ידע מוקדם או בשיטה אקראית, קוונטייזר ראשוני עם וקטורי הייצוג $\underline{\phi}_i^{(0)}$, $i = 0, 1, \dots, N-1$. בהמשך משנים את הקוונטייזר על סמך האיברים בסדרת האימון. נסמן את וקטורי הייצוג באיטרציה ה- k ע"י $\underline{\phi}_i^{(k)}$, $i = 0, 1, \dots, N-1$. עבור כל וקטור \underline{x} מסדרת האימון משווים את העיוות $d(\underline{x}, \underline{\phi}_i^{(k)})$ עבור כל וקטור ייצוג. הוקטור עם העיוות הקטן ביותר מוכרז "מנצח". וקטורי ייצוג במרחק מוגדר (סביבה כדורית) מוקטור הייצוג ה"מנצח" נקראים "שכנים של המנצח". האלגוריתם מגדיר כללי שינוי לכל אחת משלושת הקבוצות: "מנצח", "שכנים" ו"שאר העולם". הכללים מתירים שינויים גדולים יחסית בתחילת האלגוריתם. בהמשך, השינויים המתבצעים הולכים וקטנים בהתאם לפונקצית "קפיאה" (נדומה לאלגוריתם ה-Simulated Annealing שיתואר בהמשך). עבור פונקציות קפיאה איטיות, מתכנס האלגוריתם לקוונטייזר המקיים את התנאים ההכרחיים לאופטימליות.

2.2 קוונטיזציה וקטורית תחת שגיאות ערוץ

עד כה הנחנו כי הערוץ דרכו משודרים האינדקסים הינו חסר-שגיאות. כאשר מתרחש מאורע של שגיאה בערוץ, אינדקס שגוי נקלט במקלט ווקטור ייצוג שגוי מסופק ליעד. מאורע שגיאה מתואר בציר 2.2.



ציר 2.2 - מאורע של שגיאת-ערוץ בקוונטיזר וקטורי

Fig. 2.2 - Channel-Error event in a Vector Quantizer

- הוקטור $x \in R_0$ ולכן ישודר בערוץ האינדקס 3 המתאים לוקטור הייצוג ϕ_0 . בעקבות השגיאה נקלט האינדקס 2, והיעד מוזן בוקטור הייצוג ϕ_7 . בציר מתוארים הגדלים הבאים:
- עיוות הקוונטיזציה $d(x, \phi_0)$ - העיוות ללא מאורע של שגיאת ערוץ.
 - עיוות כולל $d(x, \phi_7)$ - העיוות הכולל במאורע המתואר.
 - עיוות הערוץ $d(\phi_0, \phi_7)$ - המרחק בין הוקטור שנקלט לבין הוקטור שהיה אמור להיקלט ללא שגיאת ערוץ.

אנו מניחים בעבודה זו כי הערוץ הוא חסר זיכרון וניתן לתאר את הסתברויות המעבר בערוץ ע"י מטריצת הערוץ (Channel Transition matrix) Q :

$$Q_{ij} = \text{Prob}(\text{Index } j \text{ Received} \mid \text{Index } i \text{ Transmitted}) \quad (2.11)$$

שיבוץ האינדקסים לוקטורי הייצוג מיוצג ע"י מטריצת הפרמוטציה π :

$$g(\pi) = \begin{bmatrix} \text{Index assigned to } \underline{y}_0 \\ \text{Index assigned to } \underline{y}_1 \\ \text{Index assigned to } \underline{y}_2 \\ \vdots \\ \text{Index assigned to } \underline{y}_{N-1} \end{bmatrix} = \begin{bmatrix} I_{\underline{y}_0} \\ I_{\underline{y}_1} \\ I_{\underline{y}_2} \\ \vdots \\ I_{\underline{y}_{N-1}} \end{bmatrix} = \pi \cdot \begin{bmatrix} 0 \\ 1 \\ 2 \\ \vdots \\ N-1 \end{bmatrix} \quad (2.12)$$

נסתכל על המטריצה $\pi Q \pi^T$. הכפל משמאל ב- π גורם לכך שבשורה ה- i תופיעה השורה ה- $I_{\underline{y}_i}$ של המטריצה Q . הכפל מימין ב- π^T גורם לכך שבעמודה ה- j תופיעה העמודה ה- $I_{\underline{y}_j}$ של המטריצה Q . כלומר האיבר $(\pi Q \pi^T)_{ij}$ הוא ההסתברות של המאורע: שודר האינדקס המתאים ל- \underline{y}_j ונתקבל האינדקס המתאים ל- \underline{y}_i .

לפיכך, העיוות הכולל בנוכחות שגיאות ערוץ הוא:

$$D_{\text{Total}} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \int_{R_i} d(\underline{x}, \underline{\phi}_j) \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x} \quad (2.13)$$

בתא בו מתבצע האינטגרל R_i , הוקטור \underline{x} אמור להיות מיוצג ע"י הוקטור המייצג $\underline{\phi}_i$. בגלל שגיאות הערוץ, יתכן כי וקטורים אחרים יפוענחו במקלט. ההסתברות לקליטת האינדקס המתאים לוקטור $\underline{\phi}_j$ בהינתן ששודר האינדקס המתאים לוקטור $\underline{\phi}_i$ היא כאמור $(\pi Q \pi^T)_{ij}$. עיוות הערוץ הוא ממוצע המרחק בין הוקטור שפוענח לבין הוקטור שהיה אמור להיות מפוענח ללא שגיאת ערוץ [To67]:

$$\begin{aligned} D_c &= \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \int_{R_i} d(\underline{\phi}_i, \underline{\phi}_j) \int f_{\underline{x}}(\underline{x}) \cdot d\underline{x} = \\ &= \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} d(\underline{\phi}_i, \underline{\phi}_j) p_i \end{aligned} \quad (2.14)$$

כאשר p_i היא ההסתברות לשידור האינדקס המתאים לוקטור הייצוג $\underline{\phi}_i$.

בצורה מטריצית:

$$D_c = \text{trace}\{P\pi Q\pi^T D\} \quad (2.15)$$

כאשר P היא מטריצה אלכסונית המכילה את הסתברויות המקור: $P = \text{diag}\{p_0, p_1, \dots, p_{N-1}\}$. המטריצה D היא מטריצה סימטרית המכילה את המרחקים בין

$$D_{ij} = d(\underline{\phi}_i, \underline{\phi}_j)$$

וקטורי הייצוג: $D_{ij} = d(\underline{\phi}_i, \underline{\phi}_j)$. עבור ערוץ בינארי סימטרי מועבר המידע הספרתי ע"י $L = \log_2 N$ סיביות. כאשר הסתברות שגיאה בערוץ q שואפת לאפס, ניתנת ב-[Fa90] נוסחה לחישוב ממוצע עיוות הערוץ מעל כל

השיבוצים האפשריים - \bar{D}_c .

$$\lim_{q \rightarrow 0} \frac{\bar{D}_c}{q} = \frac{L}{K(N-1)} \sum_{i=0}^{N-1} p_i \sum_{j=0}^{N-1} d(\underline{\phi}_i, \underline{\phi}_j) \quad (2.16)$$

[To67] מראים כי עבור מידת מרחק ריבועית העיוות הכולל הוא (ראה (2.13)):

$$\begin{aligned} D_{\text{Total}} &= \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \int_{R_i} \|\underline{x} - \underline{\phi}_j\|^2 \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x} = \\ &= \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \int_{R_i} \|\underline{x} - \underline{\phi}_i + \underline{\phi}_i - \underline{\phi}_j\|^2 \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x} = \\ &= \underbrace{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \int_{R_i} \|\underline{x} - \underline{\phi}_i\|^2 \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x}}_{D_c} + \\ &\quad + \underbrace{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \|\underline{\phi}_i - \underline{\phi}_j\|^2 \int_{R_i} f_{\underline{x}}(\underline{x}) \cdot d\underline{x}}_{D_c} + \\ &\quad + 2 \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} (\underline{\phi}_i - \underline{\phi}_j)^T \int_{R_i} (\underline{x} - \underline{\phi}_i) \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x} \end{aligned} \quad (2.17)$$

האיבר הראשון בסכום הוא עיוות הקוונטיזציה, D_c , המחובר השני הוא עיוות הערוץ, D_c , והמחובר השלישי כולל איברים מצטלבים.

עבור קוונטיזר המקיים את תנאי הצנטרואיד, האינטגרל במחובר השלישי מתאפס לפי (2.10) ואז:

$$D_{\text{Total}} = D_Q + D_c \quad (2.18)$$

פיתוח דומה מופיע גם ב-[Ry76]. ראוי להוסיף כי עבור קוונטיזרים עם מספר הולך וגדל של וקטורי ייצוג ($N \rightarrow \infty$) המחובר השלישי שואף לאפס גם בקוונטיזרים שאינם מקיימים את תנאי הצנטרואיד [Ze94].

בספרות קיימות שלוש גישות להקטנת העיוות בתנאי שגיאות בערוץ:

1. **הקטנת עיוות הערוץ ע"י שיבוץ אינדקסים** - עיוות הערוץ תלוי בשיבוץ האינדקסים לוקטורי הייצוג (כלומר במטריצת הפרמוטציה π). כאמור, קיימים $N!$ שיבוצים אפשריים. עבור קוונטיזר של 4 סיביות בלבד (16 וקטורי-ייצוג) ישנם $2 \cdot 10^{13} \approx 16!$ שיבוצים אפשריים. עבור קוונטיזר בן 5 סיביות ישנם $3 \cdot 10^{35} \approx 32!$ שיבוצים שונים. בגלל מספרם הרב, לא ניתן לבחון את כל השיבוצים, ולכן הוצעו שיטות שונות לת-אופטימליות למציאת שיבוץ טוב יותר. חלק מן השיטות מתוארות בסעיף 2.3. ניתן לציין במיוחד את [De87], [Ze87], [Fa90] ואת [Kn92].

הגישה הכללית לשיפור השיבוץ נקראת בספרות בשם Robust Vector Quantization.

2. **שינוי תאי החלוקה ווקטורי הייצוג** - ניתן להמיר את תנאי השכן הקרוב ותנאי הצנטרואיד לתנאים הלוקחים בחשבון את תנאי השגיאה בערוץ. ניתן לציין במיוחד תרומות של [Ku69], [Ze88], [Fa90] ואת [Fa91].

גישה זו נקראת בספרות Channel Optimized Vector Quantization. גישה זו תוצג בסעיף 2.4.

3. **תכן משולב של השיבוץ ותאי החלוקה** - שילוב של שתי הגישות הנ"ל. נציין את המקורות [Fa87] ואת [Ze88]. גישה זו תוצג בסעיף 2.5.


התנהגות טיפוסית של העיוות הכולל מתוארת בצורה סכימטית ב-[Kn92]. בסכימה (ציור 2.3)

מופיעה ההתנהגות עבור:

1. קוונטיזר "מקוריי" (a)

2. קוונטיזר עם שיבוץ טוב יותר (b)

3. קוונטיזר שעבר שינוי איזור חלוקה עבור הסתברות שגיאה נתונה בערוץ שערכה q_0 (c)



ציור 2.3 - התנהגות טיפוסית של העיוות הכולל עבור (a) - קוונטיזצור וקטורי מקורי, (b) - קוונטיזצור עם שיבוץ טוב יותר ו-(c) קוונטיזצור עם תאי חלוקה המתאימים להסתברות שגיאה בערוץ שערכה q_0

Fig. 2.3 - Typical Overall distortion characteristics for (a) Original Vector Quantizer, (b) VQ with better Index Assignment, and (c) Channel optimized VQ, designed for Channel Bit Error Rate q_0

כאשר קצב השגיאות בערוץ שואף לאפס אין השפעה של השיבוץ על העיוות הכולל והוא שואף לעיוות הקוונטיזציה. שיבוץ טוב יותר יביא לעיוות קטן יותר בתנאי שגיאות ערוץ. שינוי איזורי ההחלטה ווקטורי הייצוג עבור q_0 תרם לעיוות קטן יותר בנקודה זו. מצד שני קוונטיזצור זה שונה מן התכנ המקורי, האופטימלי ללא שגיאות ערוץ, ולכן יתפקד פחות טוב מן התכנ המקורי כאשר אין שגיאות ערוץ.

2.3 הקטנת עיוות הערוץ ע"י שיבוץ אינדקסים

ביטוי כללי לעיוות הערוץ נתקבל ב- (2.15): $D_c = \text{trace}\{P\pi Q\pi^T D\}$. עבור קוונטיזציה, מקור וערוץ נתונים, המתכנן מעוניין לבחור בשיבוץ שיביא למינימום את עיוות הערוץ מעל כל השיבוצים, π , האפשריים. בעיית שיבוץ זו ידועה בתורת חקר-הביצועים כבעיית Quadratic - QA Assignment [Gi62]. בעיית QA ידועה כבעלת סיבוכיות NP-complete [Bu79]. עבור קוונטיזציה בן N וקטורי ייצוג יש צורך לבדוק $N!$ שיבוצים אפשריים. חישוב הממוצע של עיוות הערוץ מעל כל השיבוצים האפשריים, תחת ערוץ ביטורי סימטרי, מופיע ב-[Ze94]. בנוסף, קיימת במאמר הוכחה כי הממוצע איננו שואף לאפס גם עבור מספר רב של וקטורי ייצוג ($N \rightarrow \infty$). לשינוי במספר וקטורי הייצוג ישנן שתי השלכות:

- עיוות הקוונטיזציה קטן עם תוספת וקטורי ייצוג.
- תוספת וקטורי ייצוג דורשת הגדלת האורך של מילות הקוד בערוץ ותוספת זו מגדילה את ה"פגיעות" שלהן לשגיאות. מכאן שעיוות הערוץ גדל עם תוספת של וקטורי ייצוג.

עבור קצב שגיאות נתון בערוץ, q , קיים מינימום לעיוות הכולל עבור $N_{min}(q)$ וקטורי ייצוג. בערוץ חסר שגיאות $q = 0$, נותר רק עיוות הקוונטיזציה, ולכן $N_{min}(0) \rightarrow \infty$. עם עליית קצב השגיאות בערוץ, גדל עיוות הערוץ ו- $N_{min}(q)$ הולך וקטן.

בנוסף לממוצע מעל כל השיבוצים האפשריים, מתאר [Ze94] את הווריאנס של עיוות הערוץ מעל כל השיבוצים האפשריים ומראה כי הוא שואף לאפס כאשר $N \rightarrow \infty$. עבור הגרלה אקראית של שיבוצים נקבל לכן ריכוז חזק של ביצועים סביב הממוצע. בגלל המספר הרב של שיבוצים אפשריים, בחירה אקראית של שיבוצים תתרכז סביב הממוצע ולא תביא למציאת שיבוץ טוב בזמן סביר.

תוצאות סימולציה המתוארות ב-[Kn95] מציגות בעייה נוספת. המתברר מציג היסטוגרמה של מספר השיבוצים שנתקבלו כפונקציה של עיוות ערוץ. מתברר כי העיוות הממוצע קרוב יותר לעיוות המתקבל כתוצאה מן השיבוץ הגרוע ביותר מאשר לעיוות המתקבל מן השיבוץ הטוב ביותר. קיים "זנב" בעל שכיחות נמוכה לכיוון השיבוץ הטוב ביותר, אשר מחליש את המוטיבציה לשימוש בשיבוץ אקראי.

בגלל המספר הרב של שיבוצים אפשריים, הוצעו בספרות שיטות תת-אופטימליות לשיבוץ אינדקסים. שיטות אלו מבוססות על שיפור השיבוץ ע"י החלפת זוגות. הוצע גם אלגוריתם המנסה להביא לשיבוץ גלובלי - Simulated Annealing. סקירה קצרה של גישות אלה נתונה להלן.

2.3.1 שיבוץ אינדקסים ע"י אלגוריתם החלפת זוגות

עבור ערוץ ביטורי סימטרי מאורע השגיאה הדומיננטי הוא מאורע של שגיאה בסיבית אחת. נקרא לזוג אינדקסים המרוחקים ביניהם בסיבית אחת (מרחק Hamming שווה לאחד) - אינדקסים שכנים. לכל אינדקס יש L שכנים, כמספר הסיביות בקוונטיזציה.

שיטה הכוללת שיבוץ ראשוני אד-הוק ושיפור השיבוץ ע"י חילופי אינדקסים מתוארת ב-[De87]. אלגוריתמים דומים מאד במהותם הוצגו ע"י [Ze87], [Ze90] ו-[Ch93]. האינדקס הראשון (0) משובץ לוקטור ייצוג בעל ההסתברות הגבוהה ביותר. בשלב שני משובצים האינדקסים השכנים לאינדקס הראשון לוקטורי ייצוג הקרובים לוקטור הראשון. שאר האינדקסים משובצים לוקטורי-ייצוג בני הסתברות הולכת ויורדת. כל אינדקס משובץ לוקטור הפני הקרוב ביותר לוקטורים שכבר שובצו עם אינדקסים שכנים. בשלב שני נעשה ניסיון לשפר את השיבוץ ע"י החלפת אינדקסים. אלגוריתם השיפור עובר על זוגות אינדקסים ומנסה להחליף ביניהם. מתקבל שיבוץ חדש אשר שונה מן השיבוץ הקודם בשני אינדקסים. אם השיבוץ החדש מביא לעיוות ערוץ נמוך יותר, האלגוריתם מאמץ אותו. החלפת האינדקסים עבור זוגות ממשיכה עד אשר לא ניתן יותר לשפר את עיוות הערוץ בצורה זו. האלגוריתם מבטיח התכנסות לאופטימום מקומי בלבד. ב-[Ze90] מוצגות גם תוצאות מספריות עבור מקורות מסוג גאוס-מרקוב. עבור מקור גאוס-מרקוב עם מקדם מתאם של 0.5 נבנה קוונטייזר בן 8 סיביות עם וקטורי-ייצוג בני מימד 4 (2) סיביות לדגימה). עבור הסתברות שגיאה של 1% בערוץ בינארי סימטרי נתגלה הבדל של כ-5dB בין שיבוצים גרועים לשיבוצים טובים (ראה גם ציור 6.5 בעבודה זו).

מערכת לקידוד אות דיבור מסוג Vector Adaptive Predictive Coding מתוארת ב-[Ch87]. המערכת משתמשת בקידוד LPC - Linear Predictive Coding לאות הדיבור. אות העירור (Excitation/Residual) מיוצג ע"י קוונטייזר וקטורי. שיבוץ האינדקסים לוקטורי היצוג נעשה בסוף תהליך התכן ע"י אלגוריתם דומה של החלפת אינדקסים.

2.3.2 שיבוץ אינדקסים ע"י אלגוריתם Simulated Annealing

שיטת השיבוץ ע"י החלפת זוגות של אינדקסים נותנת ערוץ היורד מונוטונית עם התקדמות האלגוריתם, אך מבטיחה התכנסות למינימום מקומי בלבד. ניסיון למציאת מינימום גלובלי לעיוות הערוץ מעל שיבוצי האינדקסים נעשה ב-[Fa90] תוך שימוש באלגוריתם של SA - Simulated Annealing. נתאר בהמשך בסעיף 2.5 מקור אחר [Cu94] העושה שימוש דומה בטכניקת SA לשיבוץ אינדקסים. אלגוריתם ה-SA מנסה למנוע את בעיית ההתכנסות למינימום מקומי בכך שניתן (בהסתברות הולכת ויורדת) לצאת ממינימום כזה. המוטיבציה לשימוש באלגוריתם ה-SA באה מתורת הגבישים. החומר ממנו עשוי הגביש מומס ומקרר לאט. הקרור האיטי מאפשר למולקולות החומר להסתדר במבנה גבישי ולהגיע לאנרגיה פוטנציאלית מינימלית. עבור בעיות קומבינטוריות קיימת פונקצית מחיר (שקולה לאנרגיה פוטנציאלית) במשתנים רבים. המשתנים קשורים ביניהם באילוצים (שקולים לקשרים כימיים). עבור האלגוריתם מגדירים גורם "טמפרטורה". גורם זה מאפשר בשלבים הראשונים של האלגוריתם לשנות במידה רבה את מצב המערכת. בהמשך מונמכת השפעת גורם ה"טמפרטורה", המערכת "מתקררת" ומתייצבת.

אלגוריתם שיבוץ אינדקסים מבוסס Simulated Annealing עפ"י [Fa90]

1. התחל בגורם טמפרטורה $T \leftarrow T_0$, ובשיבוץ התחלתי $\pi \leftarrow \pi_0$.
2. החלף באקראי זוג אינדקסים בשיבוץ וקבל שיבוץ חדש π' .
 סמן את השינוי בעיוות הערוץ ע"י $\Delta D_c = D_c(\pi') - D_c(\pi)$.
 אם השיבוץ החדש מביא לעיוות ערוץ קטן יותר יש לאמץ אותו $\pi \leftarrow \pi'$.
 אחרת יש לאמץ אותו בהסתברות $\exp(-\Delta D_c/T)$. (ההסתברות קטנה עם ירידת T)
3. אם בשלב 2 נעשו יותר ממספר מוגדר של שינויים עבור לשלב 4. אחרת חזור על 2.
4. הנמך את הגורם T . אם הגעת לטמפרטורה מוגדרת ("קפיאה") הפסק. אחרת חזור לשלב 2.

אלגוריתם ה-SA הינו יוריסטי וקיימים בו גורמים רבים המוגדרים בהתאם לדמיונו של המתכנן. כותב המאמר עמל קשה לקבלת תוצאות טובות ע"י אלגוריתם "קירור" שנבחן אמפירית. חיסרון נוסף של האלגוריתם הוא בכך ש-"קירור" האלגוריתם חייב להיות איטי להשגת תוצאות טובות, ולכן קצב ההתכנסות שלו איטי.

המאמר מתאר ניסויים רבים בקוונטיזציה וקטוריים במימדים שונים, כולם בקצב של 1 סיבית לדגימה, שתוכנו למקור גאוס-מרקוב עם מקדמי מתאם 0.0 (חסר זיכרון) ו-0.9. לדוגמה, עבור מקדם מתאם 0.9, קוונטיזציה בן 8 סיביות נתן רווח של כ-5dB מן הממוצע של עיוות הערוץ על פני כל השיבוצים האפשריים.

במאמר קיימת הבחנה מעניינת הנוגעת לאלגוריתם ה-LBG במבנה עץ שתואר בסעיף 2.1. מחבר המאמר מצא, אמפירית, כי שיבוץ האינדקסים ה-"טבעי" לוקטורי הייצוג נתן עיוות ערוץ קטן מן הממוצע של עיוות הערוץ על פני כל השיבוצים האפשריים.

2.4 שינוי תאי החלוקה ווקטורי הייצוג

תכן הקוונטיזציה ללא התחשבות בשגיאות ערוץ נעשה, כזכור, בעזרת שני תנאים הכרחיים למינימום: תנאי השכן הקרוב ותנאי הצנטרואיד. יישום לסירוגין של שני התנאים הוא הבסיס לאלגוריתמים לתכן הקוונטיזציה. בתנאי שגיאות ערוץ ניתן לפתח תנאים דומים המשקללים את העיוות לפי הסתברויות המעבר לכל הוקטורים המייצגים. הפיתוחים בסעיף זה מניחים כי גם למשדר וגם למקלט מידע על הערוץ.

2.4.1 קוונטיזציה סקלרי

פיתוח התנאים הכרחיים עבור קוונטיזציה סקלרי הפועל תחת שגיאות ערוץ נעשה ב-[Ku69] עבור מידת שגיאה ריבועית. עבור קוונטיזציה סקלרי, תנאי השכן הקרוב המשוקלל, בהתחשב בשגיאות

הערוץ, מתבטא ברמות-החלטה τ_i , $i = 0, 1, \dots, N$, כאשר $\tau_0 = -\infty$ ו- $\tau_N = +\infty$, והאחרים נתונים ע"י:

$$\tau_i = \frac{1}{2} \frac{\sum_{j=0}^{N-1} \phi_j^2 (Q_{ij} - Q_{i-1,j})}{\sum_{j=0}^{N-1} \phi_j (Q_{ij} - Q_{i-1,j})}, \quad i = 1, 2, \dots, N-1 \quad (2.19)$$

עבור ערוץ מושלם $Q = I$, מצטמצם הביטוי לכדי $\tau_i = \frac{1}{2}(\phi_i + \phi_{i+1})$. רמות הייצוג, ϕ_i , $i = 0, 1, \dots, N$, מתקבלות ע"י תנאי הצנטרואיד המשוקלל:

$$\phi_i = \frac{\sum_{j=0}^{N-1} Q_{ij} \cdot \int_{\tau_j}^{\tau_{j+1}} x \cdot p(x) dx}{\sum_{j=0}^{N-1} Q_{ij} \cdot \int_{\tau_j}^{\tau_{j+1}} p(x) dx}, \quad i = 0, 1, \dots, N-1 \quad (2.20)$$

עבור ערוץ מושלם $Q = I$, מצטמצם הביטוי להיות (2.10):

$$\phi_i = \frac{\int_{\tau_i}^{\tau_{i+1}} x \cdot p(x) dx}{\int_{\tau_i}^{\tau_{i+1}} p(x) dx}, \quad i = 0, 1, \dots, N-1 \quad (2.21)$$

יש להדגיש כי יישום התנאים לסירוגין, בנוכחות שגיאות ערוץ, בדומה לשיטת התכן המקורית של קוונטייזר איננו מבטיח התכנסות האלגוריתם, אפילו לא למינימום מקומי. לחילופין, מציעים המתברים לבצע בשלב ראשון תכן של קוונטייזר עבור ערוץ ללא שגיאות. בהמשך מעלים בצעדים איטיים את הסתברות השגיאה בתנאים (2.19) ו-(2.20) עד להתייצבות. בכל צעד המבנה שנוצר מהווה תנאי התחלה לצעד התכן הבא.

באופן דומה מגדירים המתברים את בעיית התכן לקוונטייזר סקלרי אחיד עבור שגיאות ערוץ. פתרון המשוואות המתקבלות למציאת צעד הקוונטיזציה הינו נומרי.

2.4.2 קוונטייזר וקטורי

עבור קוונטייזר וקטורי הוצעו בספרות ([Fa90], [Ze88], ו-[Fa91]) תנאים דומים לתכן: תנאי השכן הקרוב המשוקלל ותנאי הצנטרואיד המשוקלל.

תנאי השכן הקרוב המשוקלל (Weighted Nearest Neighbor Condition)

בהינתן ספר קוד C , וקטור כניסה \underline{x} ישוחרר ע"י וקטור הייצוג הקרוב אליו ביותר בשקלול שגיאות הערוץ:

$$Q(\underline{x}) = \underline{\phi}_j \text{ if } \sum_{k=0}^{N-1} Q_{jk} d(\underline{x}, \underline{\phi}_k) \leq \sum_{k=0}^{N-1} Q_{jk} d(\underline{x}, \underline{\phi}_k) \text{ for } j = 0, 1, \dots, N-1 \quad (2.22)$$

תנאי זה קובע את תאי החלוקה $R_i, i = 0, 1, \dots, N-1$. הבדיקה לאיזה תא שייך וקטור כניסה \underline{x} נעשית ע"י חישוב המרחק המשוקלל ממנו לכל וקטורי הייצוג ומציאת הקרוב אליו ביותר, במובן של מידת המרחק המשוקללת.

תנאי הצנטרואיד המשוקלל (Weighted Centroid Condition)

בהינתן חלוקת המרחב לתאי חלוקה, וקטור ייצוג $\underline{\phi}_j$ המייצג תא חלוקה R_j הוא הוקטור המביא למינימום העיוות בתא זה:

$$Q(\underline{x}) = \underline{\phi}_j \text{ for all } \underline{x} \in R_j \\ \text{if } \sum_{i=0}^{N-1} Q_{ij} \cdot E\{d(\underline{x}, \underline{\phi}_i) | \underline{x} \in R_j\} \leq \sum_{i=0}^{N-1} Q_{ij} \cdot E\{d(\underline{x}, \underline{z}) | \underline{x} \in R_j\} \text{ for all } \underline{z} \quad (2.23)$$

התנאים ההכרחיים (2.22) ו-(2.23) אינם מבטיחים כי הקוונטייזר הוקטורי יהיה רגולרי. בנוסף לכך, יישום שני התנאים לסירוגין איננו מבטיח התכנסות. גם במקרה זה הפתרון המעשי הוא תכן קוונטייזר ללא התחשבות בשגיאות ערוץ בשלב ראשון. בהמשך מעלים בהדרגה את קצב השגיאות בערוץ עד לקצב הרצוי, כפי שתואר קודם. הסתכלות על קוונטייזר וקטורי שתוכנן בהתחשב בשגיאות ערוץ מראה כי תאי החלוקה ווקטורי הייצוג "מתכווצים" לכיוון "מרכז ההסתברות" של האות.

2.4.3 תכן קוונטייזר וקטורי לפי Kohonen

גישה אחרת לתכן קוונטייזר וקטורי תחת שגיאות ערוץ מופיעה ב-[Kt92]. הגישה מבוססת על השיטה לתכן קוונטייזר וקטורי לפי Kohonen, שתוארה בסעיף 2.1.2.

השינוי באלגוריתם הוא החלפת העיוות $d(\underline{x}, \underline{\phi}_i^{(k)})$ בעיוות המשוקלל $\sum_{j=0}^{N-1} Q_{ij} d(\underline{x}, \underline{\phi}_i^{(k)})$. שימוש

מושכל בפונקציה הקפיאה מסייע בהתכנסות אלגוריתם.

2.5 תכן משולב של מבנה הקוונטייזר ושיבוץ האינדקסים

ניתן לשלב את שתי הגישות לשיפור ביצועי הקוונטייזר הוקטורי תחת שגיאות ערוץ [Ze88]. בשלב ראשון יוצרים שִיבוץ אקראי של אינדקסים. עבור שִיבוץ זה מתכננים קוונטייזר המשקלל את השפעת שגיאות הערוץ. כעת ניתן לשפר לסירוגין את השיבוץ ואת מבנה הקוונטייזר עד להתכנסות.

גישה ל"שחזור רך" (SDVQ - Soft Decision Vector Quantization) מתוארת ב-[Cu94]. בגישה שתיארנו לשינוי תאי החלוקה ווקטורי הייצוג, ה-COVQ, תמיד משוחזר וקטור ייצוג מתוך ספרית וקטורי הייצוג הקיימת. גישה ה"שחזור הרך" מציעה להתנתק מאילוץ זה. כמקודם, המקודד מחלק את קבוצת כל הוקטורים האפשריים לתאי חלוקה R_i . וקטור כניסה \underline{x} השייך לתא חלוקה R_i מיוצג בערוץ ע"י סימן ערוץ \underline{s}_i . בכניסת המפענח מתקבל משתנה אקראי \underline{y} . המפענח מבצע שיערוך של וקטור הכניסה ע"י:

$$\begin{aligned} \hat{\underline{x}}(\underline{y}) &= E[\underline{x}|\underline{y}] = \int_{\mathbb{R}^k} \underline{x} p(\underline{x}|\underline{y}) d\underline{x} = \\ &= \frac{1}{p(\underline{y})} \int_{\mathbb{R}^k} \underline{x} p(\underline{x}) p(\underline{y}|\underline{x}) d\underline{x} = \frac{1}{p(\underline{y})} \sum_{i=0}^{N-1} \int_{R_i} \underline{x} p(\underline{x}) p(\underline{y}|\underline{s}_i) d\underline{x} = \\ &= \frac{1}{p(\underline{y})} \sum_{i=0}^{N-1} p(\underline{y}|\underline{s}_i) p_i \underline{\phi}_i = \frac{\sum_{i=0}^{N-1} p(\underline{y}|\underline{s}_i) p_i \underline{\phi}_i}{\sum_{i=0}^{N-1} p(\underline{y}|\underline{s}_i) p_i} \end{aligned} \quad (2.24)$$

כאשר p_i היא ההסתברות להופעת אות הערוץ \underline{s}_i ו- $\underline{\phi}_i$ הוא הצנטרואיד של התא R_i (שאיננו וקטור שחזור במקרה זה). המפענח משחזר שיקלול של הצנטרואידים לפי ההסתברות להופעת הוקטור \underline{y} עבור כל תא חלוקה. המחברים מציגים תנאים אופטימליים לתאי החלוקה עבור ערוץ גאوسی אדיטיבי: $\underline{y} = \underline{s} + \underline{n}$, כאשר \underline{s} הוא אחד מאותות הערוץ האפשריים ו- \underline{n} הוא רכיב הרעש.

חלוקת אותות הערוץ לתאים המתאימים נעשית ע"י Simulated Annealing. בהמשך המאמר מציעים המחברים הרחבה לשיטת ה-SDVQ, המנצלת תלות בין וקטורי מקור עוקבים. המשערך לוקטור הכניסה בהינתן מוצא הערוץ מתבסס בזמן t גם על מוצא הערוץ

$$\hat{\underline{x}}(\underline{y}_{t-\tau_1}, \dots, \underline{y}_{t-1}, \underline{y}_t, \underline{y}_{t+1}, \dots, \underline{y}_{t+\tau_2})$$

בדוגמאות מספריות המוצגים במאמר מציג ה-SDVQ ביצועים עדיפים על ה-COVQ.

($N \leq M$) רמות ייצוג. עבור מקודד נתון, נעשה שימוש במפענח המשערך את רמת הכניסה בדומה ל-(2.24). עבור המקודד מתקבל תנאי השכן הקרוב המשוקלל ותנאי הצנטרואיד המשוקלל. המחברים מתארים את הסיבה לבעיית אי-ההתכנסות בתכן קוונטיזרים סקלריים המתחשבים בשגיאות הערוץ. הבעייה נובעת מכך שלא מובטח בזמן התכן כי רמות ההחלטה לא יתחלפו בסדר. כלומר גם אם בתנאי ההתחלה רמות ההחלטה מסודרות בסדר עולה $\tau_i \leq \tau_{i+1}$, הרי שיייתכן שבשלב מסוים התנאים המשקללים יהפכו את הסדר. מסיבה זו מוסיפים המחברים את תנאי הסדר באלגוריתם התכנון. תנאי זה גורם לרמות החלטה מסוימות להיעלם ($\tau_i = \tau_{i+1}$) ולהקטין בכך את מספר רמות הייצוג N . תרחיש כזה מתקיים כאשר עיוות הערוץ גדול מספיק על מנת להצדיק הורדת רזולוציה בקידוד המקור והוספת גורם תיקון שגיאות בערוץ. במאמר מוצגת דוגמה עבור מקור גאوسی ו- $M = 8$ סימני ערוץ (ערוץ בינארי סימטרי, 3 סיביות לדגימה) אפשריים. עבור הסתברויות שגיאה נמוכות ישנם $N = 8$ תאי חלוקה. רמות הייצוג וההחלטה "מתכווצות" לכיוון האפס עד להסתברות שגיאה בערוץ $q \approx 0.03$. בהסתברויות שגיאה גבוהות יותר מתאחדות רמות החלטה ויוצרות $N = 4$ תאי חלוקה בלבד.

ההתנהגות האסימפטוטית של העיוות הכולל במקודד משולב עם N וקטורי ייצוג ו- M סימני ערוץ, עבור מספר וקטורי ייצוג השואף לאינסוף מתוארת ב-[Ze94]. מידת העיוות הנבדקת היא המרחק האויקלידי בחזקת r , $\|X - Q(X)\|^r$, בהנחות המוצגות במאמר, יורד עיוות הקוונטיזציה לאפס לפחות לפי $2^{-rN/K}$ כאשר K , כזכור, הוא מימד הוקטורים עליהם מתבצע הקידוד. עיוות הערוץ יורד לאפס לפחות לפי $2^{-NE_{\max} \left(\frac{\log_2 N}{\log_2 M} \right)}$, כאשר $E_{\max}(\cdot)$ היא פונקצית האמינות המוגדרת עבור

קידוד ערוץ [Vi79]. פונקציה זו היא חיובית עבור קצבים הנמוכים מקיבול הערוץ $C < \frac{\log_2 N}{\log_2 M}$.

המסקנה היא שעבור $N \rightarrow \infty$ ניתן לבחור $M > N$ אשר יבטיח עיוות כולל השואף לאפס.

מן הראוי לציין כי איננו עוסקים בעבודת מחקר זו בתכן משולב מקור-ערוץ מן הסוג המתואר בסעיף זה.

פרק 3 - חסמים על עיוות הערוץ מעל כל המקורות האפשריים

3.1 מבוא

בפרק המבוא תיארנו את השפעת שגיאות הערוץ על ביצועי קוונטיזרים וקטוריים תחת ערוצים חסרי זיכרון. הגדרנו את עיוות הערוץ וראינו כי בתנאים מסוימים העיוות הכולל הוא סכום של העיוותים שהוגדרו כעיוות הערוץ וכעיוות הקוונטיזציה. בפרק זה נתאר שיטות לחסימה ולהערכת-ביצועים של מערכות נתונות מעל כל המקורות האפשריים. החסמים יתקבלו תוך שימוש בטכניקות של תכנות ליניארי. עבור ערוץ בינארי סימטרי (עם או בלי קוד לתיקון שגיאות) נבחן בהמשך גם את ביצועי המערכות עבור הסתברויות שגיאה נמוכות בערוץ. כן נוכיח מספר תכונות מעניינות של המקרה המיוחד: קוונטיזר סקלרי אחיד, קוד בינארי טבעי (NBC - Natural Binary Code) וערוץ בינארי סימטרי (BSC - Binary Symmetric Channel). נראה כי עיוות הערוץ במקרה זה כמעט ואיננו תלוי בהסתברויות המקור ובמספר הסיביות. נראה כי עבור קוונטיזרים בני 4 סיביות ומעלה, השיבוץ הבינארי הטבעי טוב מן הממוצע על פני כל השיבוצים, עבור כל מקור אפשרי.

3.2 חסמי ביצועים מעל כל המקורות האפשריים

ביטוי כללי לעיוות הערוץ ניתן ב-(2.15) ע"י:

$$D_c = \text{trace}\{P\pi Q_N \pi^T D\} = \sum_{i=0}^{N-1} P_{ii} \cdot (\pi Q_N \pi^T D)_{ii} \quad (3.1)$$

כאשר:

א. מטריצת הערוץ Q מתארת את ההסתברויות המעבר עבור אינדקסים המשודרים בערוץ.

$$Q_{ij} = \text{Prob}\{j \text{ received} | i \text{ transmitted}\} \quad i, j = 0, 1, \dots, N-1$$

ב. מטריצת הפרמוטציה π מתארת את שיבוץ מילות הקוד. האיבר $(\pi Q_N \pi^T)_{ij}$ הוא הסתברות

קבלת האינדקס המתאים לוקטור הייצוג $\underline{\phi}_j$ בהינתן ששודר האינדקס המתאים לוקטור הייצוג

$$\underline{\phi}_i$$

ג. מטריצת המרחקים D מתארת את המרחקים בין וקטורי הייצוג $\underline{\phi}_i$ -

$$D_{ij} = d(\underline{\phi}_i, \underline{\phi}_j) \quad i, j = 0, 1, \dots, N-1$$

ד. מטריצת ההסתברויות P היא מטריצה אלכסונית המכילה את ההסתברויות להופעת וקטור

$$P = \text{diag}\{\text{Prob}\{\underline{x} \in R_i\}\} \quad i = 0, 1, \dots, N-1 \quad R_i \text{ - בתא החלוקה}$$

עבור מערכות נתונות, ידועים הגדלים א', ב' ו-ג'. המתכנן עשוי להיות מעונין לדעת את עצמתו של עיוות הערוץ, עבור מקורות שונים. כפי שנראה ניתן באמצעים של תכנות ליניארי לקבל חסמים על עיוות הערוץ מעל כל המקורות האפשריים. בהמשך נקבל חסמים הדוקים יותר על משפחות מצומצמות יותר של מקורות.

לנוחיות הקורא מרוכזים בנספח ו' ההגדרות אשר משמשות אותנו בעבודה זו ומנוסח המשפט היסודי של התכנות הליניארי (ראה גם [Lu84]).

ניתן לחסום את עיוות הערוץ ע"י מציאת המינימום והמקסימום שלו מעל קבוצת כל המקורות האפשריים.

נציג את בעיית התכנות הליניארי הבאה:


$$\begin{aligned} \min / \max_P \quad & \sum_{i=0}^{N-1} P_{ii} \cdot (\pi Q_N \pi^T D)_{ii} \\ \text{s.t.} \quad & \sum_{i=0}^{N-1} P_{ii} = 1 \\ & P_{ii} \geq 0 \end{aligned} \quad (3.2)$$

האופטימום לבעיות המינימום והמקסימום מושגים בפתרונות הבסיסיים (Basic Solutions) של הבעיה (ראה נספח ו'). לבעיה זו יש N משתנים ואילוץ יחיד. ישנם לכן N פתרונות בסיסיים, כאשר פתרון בסיסי מתקבל ע"י איפוס של $N-1$ משתנים והשוואת המשתנה הנותר לאחד. כלומר:

$$\text{Basic solution } k \quad (k = 0, 1, \dots, N-1): \quad P_{ii} = \delta_{ik} = \begin{cases} 0 & i \neq k \\ 1 & i = k \end{cases} \quad (3.3)$$

לפתרון בעיית התכנות הליניארי עלינו לחשב את ערכי האלכסון של המטריצה $(\pi Q_N \pi^T D)$ ולאתר את האיבר הגבוה ביותר ואת האיבר הנמוך ביותר, למציאת החסם העליון והתחתון בהתאמה.

לדוגמה, עבור קוונטיזר סקלרי אחיד בן 16 רמות (4 סיביות) בתחום $[-1, 1]$, הערוץ הבינארי הסימטרי (BSC) והקוד הבינארי הטבעי (NBC) המתאים ל- $I = \pi$, חושבו החסמים, עבור הסתברויות שגיאה, q , שונות, והם מתוארים בציר 3.1.



ציור 3.1 - חסמים על עיוות הערוץ מעל כל מקורות האות האפשריים (קוונטיזר סקלרי אחיד 4 סיביות בתחום $[-1, 1]$, ערוץ בינארי סימטרי, קוד בינארי טבעי)

Fig. 3.1 - Bounds on Channel-Distortion over all possible signal sources (4 bit Uniform Scalar Quantizer covering $[-1, 1]$, Binary Symmetric Channel, Natural Binary Code)

במקרה זה ניתן לראות כי החסמים (העליון והתחתון) על עיוות הערוץ הנם קרובים מאד זה לזה וכי הביצועים של הקוונטיזר האחיד עם השיבוץ הבינארי הטבעי כמעט ואינם תלויים בסוג המקור המזין אותו. הסיבה לכך היא שבקוונטיזר סקלרי אחיד עם הקוד הבינארי הטבעי לכל סיבית מתאים עיוות אוקלידי. כלומר, עבור הסיבית המשמעותית ביותר, העיוות המתאים הוא

1; עבור הסיבית הבאה בחשיבותה העיוות המתאים הוא $\frac{1}{2^2}$ וכיו. שגיאה בסיבית מסוימת (מתוך


L סיביות) תגרום לעיוות זהה עבור כל רמת ייצוג.

ניתן להבחין כי בסקלה לוגריתמית השיפוע של החסמים הוא כמעט קבוע ושווה ל-10dB לדקדה (הקטנת קצב השגיאות פי 10 הביאה לירידה של פי 10 בעיוות הערוץ). ניתן לכן להעריך כי

החסמים יחסיים באופן ישר לשגיאה בערוץ q . נחזור לנקודה זו בסעיף 3.4.

ניתן להשתמש בטכניקת חסימה זו עבור כל ערוץ חסר זיכרון. דוגמה לערוץ כזה היא ערוץ בינארי סימטרי עם קוד לתיקון שגיאות. כאשר משדרים בערוץ את האינדקסים של וקטורי הייצוג ללא תיקון שגיאות, כל שגיאת-ערוץ גורמת להופעת וקטור ייצוג מוטעה במוצא המפענת. קוד לתיקון שגיאות משמש לגילוי ותיקון שגיאות-ערוץ שכיחות כך שלא יגרמו לוקטור ייצוג לא-מתאים להופיע במוצא המפענת. לגבי הקוונטיזר הוקטורי (והסקלרי כמקרה פרטי) מתקבל ערוץ חסר זיכרון שקול, וניתן לחשב עבורו את מטריצת הערוץ Q .

לדוגמה, עבור הקוונטיזר הסקלרי האחד מן הדוגמה הקודמת ניתן לשבץ לכל רמה מלת-קוד בת 7 סיביות תוך שימוש ב-Hamming Code (7,4) [Ta86 סעיף 13.17]. במקרה זה המרחק בין מלות קוד הוא לפחות 3 סיביות, ולכן הקוד מסוגל לתקן שגיאה בסיבית אחת. החסמים על ביצועי מערכת זו מופיעים בציר 3.2:

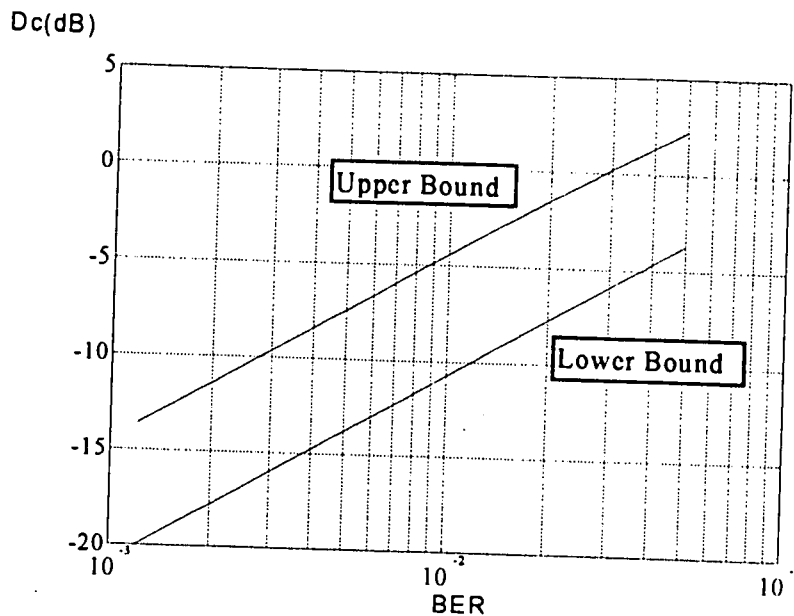


ציר 3.2 - חסמים על עיוות הערוץ מעל כל מקורות האות האפשריים עבור קוונטיזר סקלרי אחד 4 סיביות בתחום $[-1, 1]$, ערוץ בינארי סימטרי וקוד Hamming (7,4)
 Fig. 3.2 - Bounds on Channel-Distortion over all possible signal sources for 4-bit Uniform Scalar Quantizer covering $[-1, 1]$, Binary Symmetric Channel and (7,4) Hamming Code

ניתן להבחין בירידה משמעותית (קרוב ל-12dB עבור $q = 10^{-2}$) בעיוות הערוץ כתוצאה מביטול העיוות המתקבל משגיאת סיבית בודדת (המאורע השכיח ביותר). קיים הפרש של כ-3dB בין החסם העליון והחסם התחתון עבור מקורות שונים, דבר המצביע על כך שהתכונה של התאמת עיוות לסיביות במילת הקוד נעלמה.

ניתן להבחין כי בסקלה לוגריתמית השיפוע של החסמים הוא כמעט קבוע ושווה ל-20dB לדקדה (הקטנת קצב השגיאות פי 10 הביאה לירידה של פי 100 בעיוות הערוץ). ניתן להעריך כי החסמים יחסיים לריבוע השגיאה בערוץ - q^2 . נחזור לנקודה זו בסעיף 3.4.

נתבונן כעת בקוונטיזציה וקטורי בעל 256 וקטורים מייצגים (8 סיביות), בקצב של 2 סיביות לדגימה ($K = 4$) דגימות בוקטור ייצוג. הקוונטיזציה תוכנן למקור גאוס-מרקוב מסדר ראשון [Ge92] סעיף 11.4] בעל תוחלת אפס ומקדם מתאם (קורלציה) 0.5. לשם התכנון עשינו שימוש באלגוריתם ה-LBG במבנה עץ המתואר בפרק 2 [Ge92] סעיף 12.4].
 בציור 3.3 מתוארים החסמים עבור קוונטיזציה וקטורי זה:



ציור 3.3 - חסמים על עיוות הערוץ מעל כל מקורות האות האפשריים (קוונטיזציה וקטורי 8 סיביות, 2 סיביות לדגימה עבור מקור גאוס-מרקוב, ערוץ בינארי סימטרי)
 Fig. 3.3 - Bounds on Channel-Distortion over all possible signal sources (8 bit Vector Quantizer, 2 bit pre sample designed for Markov-Gaussian Source, Binary Symmetric Channel)

במקרה זה ניתן לראות כי עיוות הערוץ תלוי במקור המזין אותו. מטכניקת בניית החסמים ניתן להבין כי קיימים שני וקטורי ייצוג "טוב" ו-"גרוע". מקור המרוכז בוקטור הייצוג ה-"טוב" נותן עיוות ערוץ הקטן ב-8dB ממקור המרוכז בוקטור ייצוג "גרוע".

3.3 שיפור החסמים ע"י שימוש במומנטים

לעתים המרחק בין החסמים גדול יחסית וידיעתם איננה תורמת מספיק להערכת ביצועי המערכת. הדבר נגרם מכך שהמקורות המגשימים את החסמים אינם טיפוסיים למקור נתון. ברוב המקרים מסוג זה, בהם נתקלנו, ניתן להבחין כי החסם העליון ממומש ע"י מקור המרוכז בתאי קצה (Overload Cell) או באינטרוולי קצה בקוונטיזציה סקלריים. מקור כזה איננו מייצג נאמנה מבחינת עיוות ערוץ את המקורות הטיפוסיים המוזנים לקוונטיזציה. ניתן לקבל חסמים הדוקים יותר עבור משפחה מצומצמת יותר של מקורות, המאופיינת ע"י המומנטים של המקורות:

$$\sum_{i=0}^{N-1} P_{ii} \cdot f_k(\underline{\phi}_i) \leq M_k \quad k = 0, 1, \dots, K-1 \quad (3.4)$$

כאשר $f_k(\underline{\phi})$ הן פונקציות ידועות (לרוב, במקרה הסקלרי, $f_k(x) = x^k$) ו- M_k הוא המומנט המתאים. המומנטים המופיעים ב-(3.4) הנם אילוצים ליניאריים בהסתברויות המקור P_{ii} . אילוצים אלו מתווספים לבעיית התכנות הליניארי (3.2) ומציאת החסמים עבור משפחה זו נעשה ע"י פתרון בעיית התכנות הליניארי הבאה:

$$\begin{aligned} \min / \max_P \quad & \sum_{i=0}^{N-1} P_{ii} \cdot (\pi Q_N \pi^T D)_{ii} \\ \text{s. t.} \quad & \sum_{i=0}^{N-1} P_{ii} \cdot f_k(\underline{\phi}_i) \leq M_k \quad k = 0, 1, \dots, K-1 \\ & \sum_{i=0}^{N-1} P_{ii} = 1 \\ & P_{ii} \geq 0 \end{aligned} \quad (3.5)$$

ניתן למשל להוסיף אילוץ על ממוצע אפס: $\sum_{i=0}^{N-1} P_{ii} \cdot \underline{\phi}_i = 0$. אילוץ זה לא הביא להידוק החסמים, ברוב המקרים, מכיוון שהחסם התחתון ממומש ע"י וקטור ייצוג הקרוב לאפס והחסם העליון ממומש ע"י מקור המרוכז בשתי נקודות קצה מנוגדות כך שהממוצע הוא אפס.

3.3.1 שיפור החסמים ע"י שימוש בהגבלת הספק

דוגמה חשובה לשימוש במידע על מומנטים הוא הגבלת ההספק של המקורות. נסתכל, לדוגמה, על קוונטיזר סקלרי אחיד בתחום $[-1, 1]$, כאשר רמות הייצוג מסומנות (בסדר עולה) ב- $\phi_k, k = 0, 1, \dots, N-1$. המרחק בין רמות הייצוג יסומן ב- Δ (צעד הקוונטיזציה). הקוונטיזר מוזן ממקור בעל ממוצע אפס ושונות המנורמלת ליחידה. ניתן לחלק את שגיאת הקוונטיזציה הכוללת לשני גורמים [Ja84 סעיף 4.2]:

א. רעש גרגרי (Granular Noise) - כאשר דגימה x נמצאת בתוך "תחום" הקוונטיזר, הקרובה. מרחק זה מוגבל לחצי המרחק בין רמות ייצוג שכנות.

ב. רעש "העמסה" (Overload Noise) - כאשר דגימה x איננה נמצאת בתוך "תחום" הקוונטיזר, העיוות נגרם כתוצאה מן המרחק בין הדגימה לבין רמת הייצוג הקיצונית הקרובה יותר ($\phi_k, k = 0$ or $N-1$). מרחק זה איננו מוגבל.

בחירת צעד קוונטיזציה Δ קטן, תגרום להקטנת המרחק בין רמות-ייצוג שכנות ולכן תקטין את הרעש הגרגירי. מאידך יותר דגימות תופענה מחוץ לתחום הקוונטיזציה ורעש ה-"העמסה" יגבר. מאידך, בחירת צעד קוונטיזציה Δ גדול תגדיל את הרעש הגרגירי ותקטין את רעש הקצה. קיימת נקודה Δ_{opt} בה עיוות הקוונטיזציה הכולל המורכב משני הגורמים מגיע למינימום. את היחס בין תחום הקוונטיזציה לסטיית התקן של האות σ_x , מקובל לכנות גורם גלישה (Overload)

$$\gamma = \frac{N\Delta}{\sigma_x} \text{ - (factor)}$$

עבור קוונטיזציה סקלרית לשימושים של קידוד דיבור מקובל להשתמש בגורם גלישה γ המבטיח כי לא תיגרם גלישה בתחום של 3-4 סטיות תקן.

$$\sum_{i=0}^{N-1} P_{ii} \cdot \phi_i^2 \leq \frac{2}{\gamma^2} \quad \gamma \approx 3 \div 4$$


(3.6)

הוספת אילוץ זה לבעיית התכנות הליניארית תביא לבעיה בת 2 משוואות ב- N נעלמים. במקרה

זה ישנם $\binom{N+1}{2}$ פתרונות בסיסיים, לא כולם קבילים (Feasible), לבעיית התכנות הליניארית. יש

לחשב את ערך פונקציית המטרה ב-(3.5) עבור פתרונות אלו, ולאתר את הגבוה ואת הנמוך ביותר. כפי שראינו בציור 3.1 אין משמעות לחפש חסמים הדוקים יותר עבור הקוונטיזציה הסקלרית האחיד עם השיבוץ הבינארי הטבעי. מסיבה זו נשתמש כאן בקוד Gray, כדי להדגים את שיפור החסמים ע"י הוספת אילוץ של הגבלת הספק.

בציור 3.4 מתוארים החסמים לקוונטיזציה סקלרית אחיד בן 16 רמות בתחום $[-1, 1]$, כאשר הפעם, כאמור, נעשה שימוש בקוד Gray. החסמים, בניגוד לשיבוץ הבינארי הטבעי, אינם מתלכדים. בציור מתוארים החסמים עבור גורמי גלישה $\gamma = 1, 2, 4$. גורם גלישה $\gamma = 1$ מביא לחסם הבסיסי.



ציור 3.4 - חסמים על עיוות הערוץ מעל משפחות מקורות בעלות גורמי גלישה נתונים (קוונטיזר סקלרי אחד 4 סיבית בתחום $[-1, 1]$, ערוץ בינארי סימטרי, קוד Gray)
 Fig 3.4 - Bounds on Channel-Distortion over signal sources with specific overload factors. (4 bit Uniform Scalar Quantizer covering $[-1, 1]$, Binary Symmetric Channel, Gray Code)

החסם התחתון משותף לכל גורמי הגלישה והוא ממומש ע"י מקור המרוכז באפס. מן החסם התחתון נראה כי עבור מקורות "טובים" הקוד נותן ביצועים הטובים בערך ב-4dB מביצועי הקוד הבינארי (מתוך השוואה עם ציור 3.1). החסמים העליונים ממומשים במקורות המרוכזים בקצות התחום המותר ע"י הגבלת ההספק. הגדלת גורם הגלישה (ובכך הקטנת הספק האות) מביאות להורדת החסם העליון. עבור גורם גלישה $\gamma = 4$, גם החסם העליון נמוך מן העיוות הנגרם עבור קוד בינארי טבעי. מכאן ששיבוץ בקוד Gray עדיף על שיבוץ בקוד הבינארי הטבעי עבור מקורות המקיימים את מגבלת ההספק המתאימה ל- $\gamma \geq 3$. בפרק 5 נראה כי עבור מקור אחד ביצועי השיבוץ הבינארי הטבעי הם העדיפים.

3.4 חסימת עיוות הערוץ עבור קצבי שגיאות קטנים

נסתכל על הערוץ הבינארי הסימטרי או על ערוצים הנובעים ממנו ע"י קוד בלוק לתיקון שגיאות כדוגמת קוד Hamming שתואר בציור 3.2. איברי מטריצת הערוץ Q תלויים בהסתברות השגיאה בערוץ הבינארי הסימטרי - q . נסמן עובדה זו באופן מפורש ע"י $Q(q)$. עבור קצבי שגיאות קטנים אברי האלכסון במטריצת הערוץ Q הם הדומיננטיים. מאידך, מכיוון שהמרחק בין ווקטור ייצוג לעצמו הוא תמיד אפס, איברים אלו מוכפלים באפסים וניתן לאפס את האלכסון של מטריצת הערוץ Q .

נגדיר:

$$\bar{Q}_j(q) = \begin{cases} Q_j(q) & i \neq j \\ 0 & i = j \end{cases} \quad (3.7)$$

כעת נחפש את גורם השגיאה הדומיננטי בשאר איברי מטריצת הערוץ. המטריצה $\bar{Q}(q)$ מורכבת מסכומים של איברים מן הצורה $q^l(1-q)^{L-l}$ $l = L^0, L^0 + 1, \dots, L$, כאשר סימנו את החזקה הנמוכה ביותר ב- L^0 . הסיבה לכך שאיפסנו את האלכסון של המטריצה המקורית $Q(q)$ היא שהיו באלכסון איברים בחזקות נמוכות יותר מ- L^0 . נבחר את הגבול:

$$\lim_{q \rightarrow 0} \frac{1}{q^{L^0}} \cdot \bar{Q}(q) = \bar{Q}_A \quad (3.8)$$

איברים עם חזקות של q הגבוהות מ- L^0 יתאפסו בגבול. הגבול של עיוות הערוץ עבור קצבי שגיאה נמוכים בערוץ הוא לכן:

$$\lim_{q \rightarrow 0} \frac{1}{q^{L^0}} D_c = \text{trace} \{ P \pi \bar{Q}_A \pi^T D \} \quad (3.9)$$

ניתן בצורה זו למצוא את ההתנהגות האסימפטוטית של עיוות הערוץ. עבור הסתברויות שגיאה קטנות (מתחת לאחוז אחד) ההשפעה של גורם מסוג $q^l(1-q)^{L-l}$ גדולה בלפחות 20dB מהשפעתו של גורם מסוג $q^{l+1}(1-q)^{L-l-1}$. בהמשך ניוכח לדעת כי ההתנהגות האסימפטוטית קרובה מאד להתנהגות המדויקת אפילו עבור הסתברויות שגיאה גבוהות יחסית של 5 אחוז.

ניתן להיעזר בטכניקות החסימה (מעל כל המקורות האפשריים) שתוארו בסעיף 3.2 גם לקבלת ההתנהגות האסימפטוטית של החסמים על עיוות הערוץ עבור קצבי שגיאות קטנים ($q \rightarrow 0$). ניתן גם לשפר את החסמים בעזרת המידע על מומנטים כפי שנעשה בסעיף 3.3. לדוגמה, עבור הערוץ הבינארי הסימטרי קצב השגיאה הדומיננטי הוא $L^0 = 1$. החסמים יהיו על

$$\text{הגודל: } \lim_{q \rightarrow 0} \frac{1}{q} D_c$$

בציור 3.1 ובציור 3.4 תיארנו את הביצועים של קוונטיזר אחיד בן 4 סיביות בתחום $[-1, 1]$ עבור קוד בינארי סימטרי ועבור קוד Gray בהתאמה.


במקרים אלו נתקבלו הקבועים הבאים:

Code	Asymptotic Lower Bound	Asymptotic Upper Bound
Natural Binary	1.33	1.33
Gray	$\gamma = 1$	4.43
	$\gamma = 2$	2.06
	$\gamma = 4$	0.94

טבלה 3.1 - חסמים על הערכים האסימפטוטיים של עיוות הערוץ המנורמל (D_c/q) מעל כל המקורות האפשריים, ומעל מקורות עם הגבלת הספק (קוונטיזר אחד 4 סיבית בתחום $[-1, 1]$, ערוץ בינארי סימטרי)

Table 3.1 - Bound on the asymptotic Normalized Channel-Distortion (D_c/q) over all possible signal sources and power limited source (4 bit Uniform Quantizer range $[-1, 1]$, Binary Symmetric Channel)

בציור 3.5 מתוארים הערכים האסימפטוטיים בהשוואה לחסמים המקוריים עבור קוד Gray מצויר 3.4.



ציור 3.5 - חסמים על עיוות הערוץ מעל משפחות מקורות בעלות גורמי גלישה נתונים (קוונטיזר סקלרי אחד 4 סיבית בתחום $[-1, 1]$, ערוץ בינארי סימטרי, קוד Gray) בהשוואה לחסמים אסימפטוטיים


Fig 3.5 - Bounds on Channel-Distortion over signal sources with specific overload factors. (4 bit Uniform Scalar Quantizer range $[-1, 1]$, Binary Symmetric Channel, Gray Code) Compared with Asymptotic bounds

ניתן לראות כי ההתנהגות האסימפטוטית קרובה מאד להתנהגות האמיתית עד להסתברות שגיאה של כ-5 אחוז.

דוגמה נוספת: עבור הערוץ הבינארי הסימטרי עם קוד Hamming (7,4) לתיקון שגיאות, קצב השגיאה הדומיננטי הוא $L^0 = 2$. עבור קוונטיזר אחיד בן 4 סיביות בתחום [-1,1] וקוד תיקון זה (הופיע בציר 3.2), ההתנהגות האסימפטוטית היא:

$$-7.98 \leq \lim_{q \rightarrow 0} \frac{1}{q^2} D_c \leq -18.45 \quad (3.10)$$

בציר 3.6 מתוארים הערכים האסימפטוטיים בהשוואה לחסמים המקוריים.



ציר 3.6 - חסמים על עיוות הערוץ מעל כל מקורות האות האפשריים עבור קוונטיזר סקלרי אחיד 4 סיביות, ערוץ בינארי סימטרי וקוד Hamming (7,4) בהשוואה לחסמים אסימפטוטיים

Fig. 3.6 - Bounds on Channel-Distortion over all possible signal sources for 4-bit Uniform Scalar Quantizer, Binary Symmetric Channel and (7,4) Hamming Code. The exact bound are compared with asymptotic bounds

גם במקרה זה ניתן לראות כי ההתנהגות האסימפטוטית קרובה מאוד להתנהגות המדויקת עד להסתברויות שגיאה של כ-5 אחוז.

3.5 הקוונטיזר הסקלרי האחיד עם הקוד הבינארי הטבעי תחת ערוץ בינארי סימטרי

בסעיף זה נסקור מספר תכונות מעניינות המתקבלות במקרה המיוחד של קוונטיזר סקלרי אחיד וקוד בינארי טבעי (NBC) תחת הערוץ הבינארי הסימטרי (BSC). מטבלה 3.1 ומציר 3.1 ניתן לראות כי החסם העליון והתחתון על עיוות הערוץ מתלכדים עבור הסתברויות שגיאה בערוץ הקטנות מחמישה אחוז. המסקנה היא שביצועי הקוונטיזר הסקלרי

האחיד במקרה זה אינם תלויים בהסתברויות של מקור האות. כאמור, הסיבה לכך היא שעבור הקוד הבינארי הטבעי לכל סיבית ניתן להתאים עיוות ריבועי אוקלידי. לספרה המשמעותית ביותר יש ערך יחסי השווה 1^2 , לסיבית השנייה ערך $\frac{1}{2^2}$ וכו'. עבור הסתברויות שגיאה נמוכות, מאורע השגיאה השכיח של שגיאה בסיבית אחת ייתן בהסתברות שווה עיוות לפי ערכים אלו, ללא תלות במקור. בטבלה 3.2 מופיעים החסמים האסימפטוטיים עבור קוונטיזרים סקלריים אחידים עבור מספר סיביות שונה.

Number of bits	Asymptotic Upper and Lower Bounds $\lim_{q \rightarrow 0} D_c/q$
2	1.250
3	1.313
4	1.328
5	1.332
6	1.333
7	1.333
8	1.333

טבלה 3.2 - חסמים אסימפטוטיים על עיוות הערוץ עבור קוונטיזרים סקלריים אחידים בתחום $[-1, 1]$ עם מספר סיביות שונה, שיבוץ בינארי טבעי תחת ערוץ בינארי סימטרי

Table 3.2 - Asymptotic bounds on the channel distortion for scalar quantizers in the range $[-1, 1]$ with various number of bits,


Natural Binary Code and Binary Symmetric Channel

מן הטבלה ניתן לראות כי עיוות הערוץ במקרה זה כמעט ואיננו תלוי במספר הסיביות L של

הקוונטיזר הסקלרי. הסיבה לכך היא שסכום הערכים: $\sum_{l=0}^{L-1} \frac{1}{(2^l)^2}$ מתכנס במהירות לערך $\frac{4}{3}$.

נקדים את המאוחר ונציין כי בפרק 5 מופיעה הוכחה כי השיבוץ הבינארי הטבעי הוא השיבוץ האופטימלי עבור קוונטיזר סקלרי אחיד, מקור אחיד וערוץ בינארי סימטרי. כאן נראה כי עבור כל מקור שהוא, השיבוץ הבינארי הטבעי טוב מן הממוצע על כל השיבוצים האפשריים.

ממוצע העיוות (Ensemble Average) - \bar{D}_c הוא הממוצע של עיוות הערוץ על פני כל השיבוצים האפשריים של מילות קוד לוקטורי-ייצוג (סה"כ $N!$). ב-[Fa90] מופיע חישוב אסימפטוטי של ממוצע העיוות עבור הערוץ הבינארי הסימטרי. במקרה זה ניתן להגיע לביטוי פשוט לממוצע העיוות (מוצג בהמשך). רמות הייצוג מתוארות בצירוף 3.7.



ציר 3.7 - רמות הייצוג של קוונטייזר אחיד סקלרי מסוג Midrise

Fig. 3.7 - Representing levels of a Midrise scalar uniform quantizer

נתאר את רמות הייצוג בוקטור עמודה:

$$\underline{\rho} = \begin{bmatrix} \rho_0 \\ \rho_1 \\ \vdots \\ \rho_i \\ \vdots \\ \rho_{N-1} \end{bmatrix} = \frac{2}{N} \begin{bmatrix} -N/2 + 1/2 \\ 1 - N/2 + 1/2 \\ \vdots \\ i - N/2 + 1/2 \\ \vdots \\ N/2 - 1 + 1/2 \end{bmatrix} \quad (3.11)$$

חישוב ממוצע העיוות נותן:

$$\begin{aligned} \lim_{q \rightarrow 0} \frac{\bar{D}_c}{q} &= \lim_{q \rightarrow 0} \frac{1}{q} \left(\frac{1}{N!} \sum_{\text{Every assignment } \pi} D_c(\pi) \right) = \\ &\Leftarrow [\text{Fa90}] \\ &= \frac{L}{N-1} \sum_{i=0}^{N-1} P_i \sum_{j=0}^{N-1} (\rho_i - \rho_j)^2 = \\ &= \frac{(4N-2)L}{3N} - \frac{4L}{N(N-1)} \sum_{i=0}^{N-1} P_i [(N-1)i - i^2] \end{aligned} \quad (3.12)$$

האיבר השני בסכום כולל ממוצע משוקלל של איברי "פרבולה" בדידה. ניתן לחסום את ממוצע העיוות ע"י הצבת הערך הגבוה והערך הנמוך ב"פרבולה" זו. מכאן מתקבל:

$$\begin{aligned} \left(\lim_{q \rightarrow 0} \frac{\bar{D}_c}{q} \right)_{\min} &= \frac{L}{3N} \left[N+1 + \frac{3}{N-1} \right] \approx \frac{1}{3} L \\ \left(\lim_{q \rightarrow 0} \frac{\bar{D}_c}{q} \right)_{\max} &= \frac{(4N-2)L}{3N} \approx \frac{4}{3} L \end{aligned} \quad (3.13)$$

כאשר L הוא מספר הסיביות ו- $N = 2^L$ מספר הרמות בקוונטיזציה הסקלרית האחד. בטבלה 3.3 מופיעים ערכי המינימום והמקסימום של ממוצע העיוות האסימפטוטי (מנורמל להסתברות השגיאה בערוץ) בהשוואה לעיוות הנגרם עבור הקוד הבינארי הטבעי, עבור קוונטיזציה סקלרית עם מספר שונה של סיביות.

No. of bits (L)	2	3	4	5	6	7	8
Natural Binary Code	1.25	1.31	1.33	1.33	1.33	1.33	1.33
Ensemble Av. Lower Bound	1.00	1.18	1.43	1.72	2.03	2.35	2.68
Ensemble Av. Upper Bound	2.33	3.75	5.17	6.56	7.94	9.30	10.65

טבלה 3.3 - חסמים אסימפטוטיים מעל כל המקורות האפשריים על ממוצע עיוות הערוץ על פני כל השיבוצים האפשריים (\bar{D}_c/q) , בהשוואה לביצועי הקוד הבינארי הטבעי עבור קוונטיזציה סקלרית אחידים עם מספר סיביות שונה

Table 3.3 - Asymptotic bounds over all possible source probabilities on the Channel Distortion Ensemble Average over all possible assignments (\bar{D}_c/q) , compared with the performance of the Natural Binary Code assignment.

מן הטבלה ניתן להבחין כי ממוצע העיוות עולה עם מספר הסיביות L , בעוד שהקוד הבינארי הטבעי שומר על עיוות כמעט קבוע. עבור קוונטיזציה בני ארבע סיביות ויותר, הקוד הבינארי הטבעי טוב אפילו מן החסם התחתון על ממוצע העיוות ולכן טוב מממוצע העיוות עבור כל הסתברויות המקור האפשריות. תכונה זו מתאימה לאובזרבציה של [Fa90] אשר מצא אמפירית כי עבור קוונטיזציה וקטורית במבנה עץ, השיבוץ הטבעי נותן עיוות הנמוך מן הממוצע על עיוות הערוץ על פני כל השיבוצים האפשריים.

3.6 סיכום

בפרק זה קיבלנו חסמים על עיוות הערוץ מעל כל המקורות האפשריים המזינים את הקוונטייזר. הצגנו דוגמאות מספריות שונות עבור ערוץ בינארי סימטרי בלי ועם קוד לתיקון שגיאה בסיבית אחת. ראינו כי במקרים טיפוסיים החסם התחתון ממומש ע"י מקור המרוכז בנקודה אחת בסביבת האפס, כאשר החסם העליון ממומש ע"י מקור המרוכז בתא קצה. מסיבה זו הצלחנו לקבל חסמים הדוקים יותר כאשר צמצמנו את משפחת המקורות ע"י תוספת אילוצי-מומנטים ובעיקר הגבלת הספק. ראינו דרך למציאת חסמים על ההתנהגות האסימפטוטית של עיוות הערוץ עבור הסתברויות שגיאה קטנות. נוכחנו לראות כי בדוגמאות שהוצגו ההתנהגות האסימפטוטית קרובה להתנהגות המדויקת גם בהסתברויות שגיאה בערוץ של עד כחמישה אחוז.

עבור המקרה המיוחד של קוונטייזר סקלרי אחיד ושיבוץ בינארי סימטרי ראינו כי עיוות הערוץ כמעט ואיננו תלוי במקור וכמעט ואיננו תלוי במספר הסיביות של הקוונטייזר. ראינו גם כי השיבוץ הבינארי הטבעי נותן עיוות ערוץ נמוך יותר מממוצע עיוות הערוץ על פני כל השיבוצים (Ensemble Average) האפשריים עבור כל מקור שהוא, עבור 4 סיביות ויותר.

פרק 4 - כיווץ ליניארי של קוונטיזרים וקטוריים להקטנת

העיוות בתנאי שגיאות ערוץ

4.1 מבוא

בסקר הספרות תיארנו את התנאים ההכרחיים לקוונטיזר וקטורי אופטימלי הפועל תחת שגיאות ערוץ בשיבוץ אינדקסים נתון. ראינו כי תנאי השכן הקרוב ותנאי הצנטרואיד הוחלפו בתנאים דומים המשקללים את השפעת שגיאות הערוץ. קוונטיזר מסוג זה נקרא בספרות [Kn92] בשם COVQ - Channel Optimized Vector Quantizer.

תכן קוונטיזר מסוג COVQ הוא קשה ומסובך הרבה יותר מתכן שאיננו מתחשב בשגיאות ערוץ. תוצאת התכן היא משפחה של קוונטיזרים וקטורים (ספרי-קוד של וקטורי ייצוג) המתאימים כל אחד להסתברויות שגיאה (BER - Bit Error Rate) אחרת בערוץ. מסיבה זו המימוש של COVQ הוא יקר יחסית בדרישות זיכרון הן במשדר והן במקלט.

בפרק זה מוצע מבנה פשוט של קוונטיזר וקטורי להקטנה תת-אופטימלית של השפעת שגיאות הערוץ. השינוי המוצע הוא כיווץ ליניארי של מבנה הקוונטיזר (שתוכן ללא התחשבות בשגיאות ערוץ) אותו נכנה - SVQ - Scaled Vector Quantizer.


תכן הקוונטיזר נעשה בשני שלבים: בשלב ראשון תכן קוונטיזר ללא התחשבות בשגיאות הערוץ (NVQ - Noiseless Vector Quantizer) ובשלב שני מציאת גורמי הכיווץ המתאימים לקצבי שגיאות שונים בערוץ. גם המימוש הוא פשוט בהרבה יחסית ל-COVQ. מספיק לשמור את ספר הקוד של ה-NVQ וטבלה של סקלרים המתאימים לערכי BER שונים.

בדוגמאות מספריות אנו מראים ביצועי ה-SVQ נופלים במידה "סבירה" מביצועי ה-COVQ בהתחשב בפישוט התכן והמימוש.

4.2 תיאור הכיווץ הליניארי בקוונטיזר וקטורי

מערכת תקשורת המבוססת על קוונטיזר וקטורי המתוכנן ללא התחשבות בשגיאות ערוץ מתוארת בציר 4.1. בהמשך נקרא לסוג זה של קוונטיזר בשם NVQ - Noiseless Vector Quantizer. תכן הקוונטיזר נעשה בשיטות ה-"קלסיות" המקובלות.

כזכור, התנאים ההכרחיים לאופטימום הם תנאי השכן הקרוב (2.8) ותנאי הצנטרואיד (2.9). אלגוריתמים לתכן NVQ כדוגמת LBG או Generalized-Lloyd (ראה [Ge92], סעיף 11.3) מבוססים על יישום לסירוגין של התנאים ההכרחיים על סדרות אימון (או על הסתברות המקור, כאשר היא ידועה). שיטת תכן זו מבטיחה התכנסות למינימום לוקלי. כאשר מופעל NVQ תחת שגיאות ערוץ נגרמת הרעה בביצועי המערכת כפי שתוארה בסקר הספרות (סעיף 2.2).




ציור 4.1 - מערכת קוונטיזציה וקטורית

Fig. 4.1 - Vector Quantization System

כאמור, בספרות הוצעו תנאים הכרחיים אלטרנטיביים לאופטימום של קוונטיזציה וקטורית תחת שגיאות ערוץ - [Fa90], [Ze88], [Ku69] ו-[Fa91]. התנאים ההכרחיים הינם תנאי השכן הקרוב המשוקלל (2.22) ותנאי הצנטרואיד המשוקלל (2.23). בניגוד למקרה בו לא קיימות שגיאות ערוץ, יישום לסירוגין של שני התנאים איננו מבטיח התכנסות. כמו-כן לא מובטחת רגולריות במבנה הקוונטיזציה.

בפועל מתכננים בשלב ראשון קוונטיזציה ללא התחשבות בשגיאות הערוץ - NVQ. בהמשך מריצים את אלגוריתם התכן עבור קצב שגיאות נמוך, כאשר ה-NVQ מהווה את תנאי ההתחלה לתכן. בהמשך, בכל שלב בתכן מעלים בהדרגה את גורם קצב שגיאות הערוץ בתנאים (2.22) ו-(2.23), כאשר תנאי ההתחלה הם תוצאות שלב התכן הקודם. בצורה זו מקבלים סדרה של קוונטיזציות שונים המותאמים כל אחד לקצב שגיאות שונה בערוץ. לקוונטיזציה שתוכנן בדרך זו נקרא COVQ Channel Optimized Vector Quantizer - ומערכת תקשורת מתאימה מתוארת בציור 4.2.




ציור 4.2 - מערכת קוונטיזציה וקטורית מותאמת לערוץ

Fig. 4.2 - Channel Optimized Vector Quantization System

מכיוון שתכן ה-COVQ תלוי בקצב השגיאות בערוץ, הרי שגם המשדר וגם המקלט צריכים לדעת את תנאי הערוץ. לשם כך יש להוסיף למערכת מודול ניטור ערוץ (Channel Monitor). מודול הניטור מודיע למשדר ולמקלט על תנאי הערוץ ושניהם בוחרים את הקוונטיזציה המתאימה לקצב השגיאות הנתון. החיסרון הבולט במימוש של גישה זו הוא הצורך בקוונטיזציה שונים עבור תנאים שונים של שגיאות הערוץ. דרישה זו באה לידי ביטוי בדרישות זיכרון במקלט ובמשדר לשמירת סדרת הקוונטיזציות.

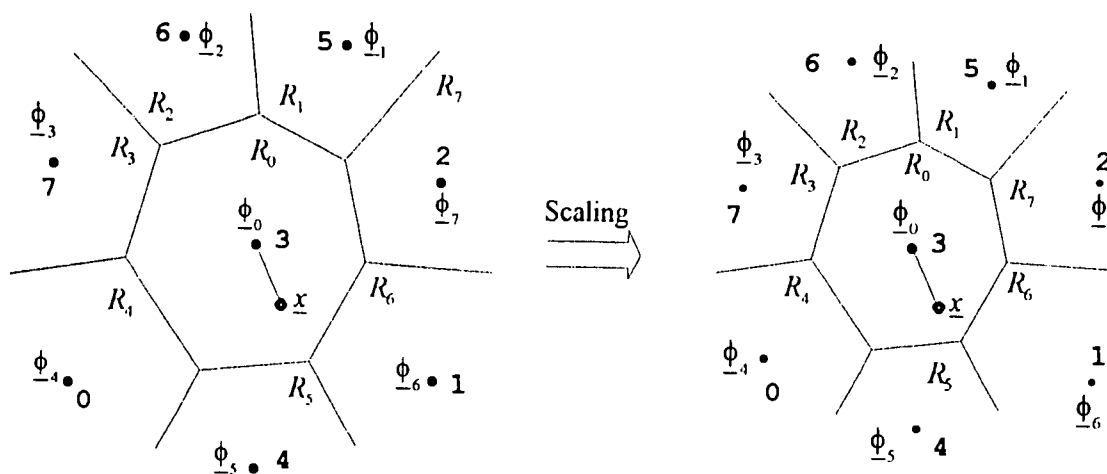
בתכן קוונטיזציה המותאמים לערוץ (COVQ) ניתן להבחין בהצטופפות וקטורי הייצוג סביב "מרכז הכובד" של הסתברות המקור. להצטופפות וקטורי הייצוג ישנם שתי השפעות מנוגדות. מצד אחד כל זוג של וקטורי ייצוג מתקרבים זה לזה ולכן שגיאת ערוץ תביא לעיוות קטן יותר. מצד שני הקוונטיזציה מתרחקת מן התכן ללא שגיאות ערוץ ולכן נפגעת התאמתו למקור. בפרט, רעש "ההעמסה" (Overload) יגדל עם כיווץ הקוונטיזציה. ככל שיגבר קצב השגיאות בערוץ, תגדל השפעתו של גורם שגיאות הערוץ והקוונטיזציה יהיה צפוף יותר. הבחנה זו נתנה את המוטיבציה לדרך ביניים להקטנת השפעת שגיאות הערוץ והיא כיווץ ליניארי של מבנה הקוונטיזציה - SVQ - Scaled Vector Quantizer - המתוארת בצירוף 4.3.



צירוף 4.3 - מערכת קוונטיזציה וקטורית עם כיווץ ליניארי

Fig. 4.3 - Scaled Vector Quantization System

המקודד והמפענח במערכת ה-SVQ זהים לקוונטיזציה שתוכנן ללא התחשבות בשגיאות הערוץ - NVQ. השינוי להקטנת השפעתן של שגיאות הערוץ הוא כפל בסקלר $1/\alpha$ במבוא המקודד וכפל בסקלר α במוצא המפענח. הסקלר יכול לקבל ערכים בתחום $0 < \alpha \leq 1$. בתאור המערכת הנחנו ממוצע אפס של אות המקור כך שכפל בסקלר שקול להצטופפות סביב מרכז ההסתברות. בצירוף 4.4 מתוארים השינויים כתוצאה מן הכפל בסקלר:



צירוף 4.4 - תאור סכימטי של קוונטיזציה וקטורית עם כיווץ ליניארי

Fig. 4.4 - Schematic drawing of a Scaled Vector Quantizer

הכפל במבוא המקודד בסקלר α^{-1} גורם לכך שלמקודד מוצג הוקטור ה"מוגדל" $\alpha^{-1}\underline{x}(t)$. מנקודת מבטו של המקור היה עליו להפיק את הוקטור $\alpha\underline{x}(t)$ על מנת לשמור את מבנה תאי החלוקה בקוונטיזר. לפיכך הכפל במבוא המקודד שקול לכיווץ בפקטור α של תאי החלוקה. הכפל במוצא המפענת בסקלר α שקול לכיווץ הוקטורים המייצגים. עבור מצבים שונים של שגיאות בערוץ ניתן לחפש Off-Line את הערך האופטימלי של הסקלר α . במימוש אין צורך להחזיק ספרייה של קוונטיזרים וקטוריים כדוגמת ה-COVQ. במקום זאת, מספיק לשמור במשדר ובמקלט מימוש של קוונטיזר יחיד ובנוסף טבלה (Look-Up-Table) המחזיקה ערכים אופטימליים של הסקלר α . בהמשך הפרק נדון בביצועים של SVQ ונציג מספר דוגמאות מספריות.

4.3 קוונטיזר וקטורי עם כיווץ ליניארי (Scaled Vector Quantizer)

נסתכל על קוונטיזר וקטורי עם כיווץ ליניארי הפועל בתנאי ערוץ בינארי סימטרי. בפרק זה נשתמש במידת מרחק ריבועית. כאמור, הסקלר α גורם לכיווץ תאי החלוקה ולהצטופפות של וקטורי הייצוג. העיוות הכולל (2.17) עבור מקרה זה הוא:

$$D_{\text{Total}}(\alpha) = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \int_{R_i(\alpha)} \|\underline{x} - \alpha \underline{\phi}_j\|^2 \cdot f_{\underline{x}}(\underline{x}) \cdot d\underline{x} \quad (4.1)$$

כאשר תא החלוקה החדש מוגדר ע"י $\underline{x} \in R_i \Leftrightarrow \alpha \underline{x} \in R_i(\alpha)$ וכן $R_i(1) = R_i$. עבור הערוץ הבינארי הסימטרי $Q_{ij} = q^{H(i,j)}(1-q)^{L-H(i,j)}$ כאשר $H(i,j)$ הוא מרחק Hamming בין הייצוגים הבינאריים של המספרים i ו- j ו- $L = \log_2 N$ הוא מספר הסיביות. עבור קוונטיזר ומקור נתונים ועבור הסתברות שגיאה נתונה בערוץ q , מידת המרחק הכוללת $D_{\text{Total}}(\alpha)$ היא פונקציה במשתנה אחד α . עבור הסתברויות שגיאה שונות ניתן לחשב Off-Line את גורם הכיווץ האופטימלי $\alpha_{\text{opt}}(q)$. במימוש המערכת ניתן לאכסן את $\alpha_{\text{opt}}(q)$ בטבלה אשר תימצא גם במשדר וגם במקלט. בדוגמאות המספריות המוצגות בהמשך הפרק נראה כי במקרים שנבחנו, הפונקציה $\alpha_{\text{opt}}(q)$ היא פשוטה לתיאור. יתרה מזו, לפונקצית מידת המרחק הכוללת $D_{\text{Total}}(\alpha)$ קיים בדוגמאות מינימום שטוח כך שידעת הסתברות השגיאה המדויקת איננה הכרחית. לחילופין, אין צורך בידיעה מדויקת של $\alpha_{\text{opt}}(q)$. עבור $\alpha = 1$ מתקבל העיוות עבור הקוונטיזר שתוכנן ללא התחשבות בשגיאות ערוץ - NVQ. לכן ללא שגיאות בערוץ $q = 0$, המינימום של $D_{\text{Total}}(\alpha)$ יימצא ב- $\alpha = 1$.

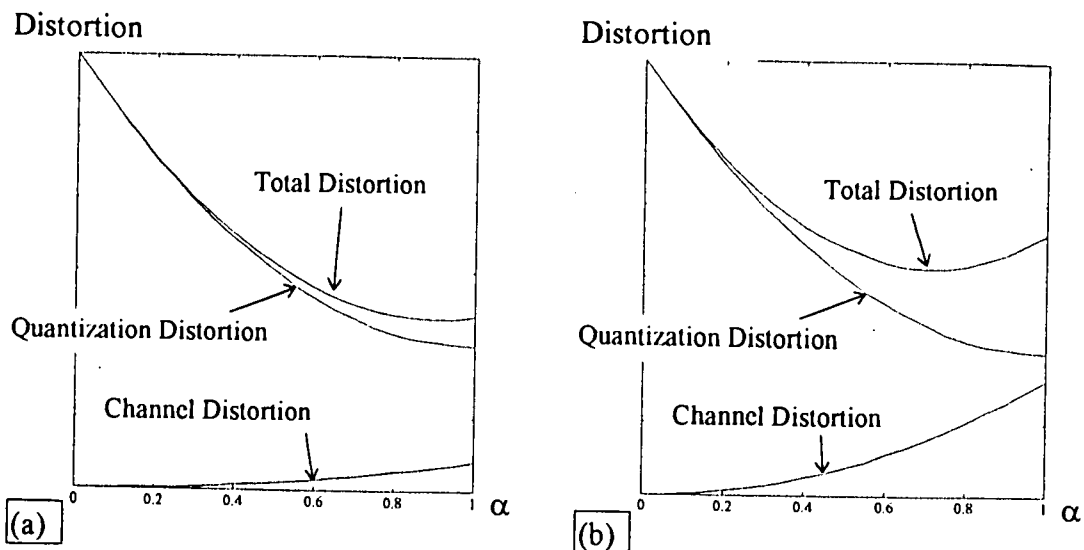
כללית, לשינוי ב- α ישנן שתי השלכות:

- א. תזווה מן התכן המקורי המתחשב במקור בלבד (ולא בשגיאות הערוץ), ה-NVQ. נצפה כי הגדלת α או הקטנתו תגדיל את עיוות הקוונטיזציה.
- ב. הקטנת α תגרום לכל זוג וקטורי ייצוג להתקרב זה לזה. השפעתו של העיוות כתוצאה משגיאה בערוץ תקטן. הגדלת α תגדיל בהתאם את עיוות הערוץ.

ההתנהגות הטיפוסית של הפונקציה $D_{Total}(\alpha)$ תהיה:

- א. הגדלת α לערך הגדול מ-1 תגרום להגדלת העיוות הכולל.
- ב. לפונקציה יש מינימום בתחום $0 < \alpha \leq 1$.
- ג. מיקומו של המינימום יהיה קרוב ל-1 עבור הסתברויות שגיאה קטנות בערוץ והוא יתקרב לאפס עם הגדלת קצב השגיאות בערוץ.

תיאור סכימטי של העיוותים במערכת בתלות בסקלר α עבור עיוות ערוץ נמוך ועבור עיוות ערוץ גבוה מופיע בציר 4.5:



ציר 4.5 - תיאור סכימטי של עיוותים טיפוסיים כפונקציה של גורם הכיווץ α

(a) - עיוות ערוץ נמוך, (b) - עיוות ערוץ גבוה

Fig 4.5 - Schematic drawing of typical distortion as a function of the scaling factor α

(a) - Low Channel Distortion, (b) - Severe Channel Distortion

מן הסכימה ניתן לראות כי עבור עיוות ערוץ נמוך (a), העיוות הכולל כפונקציה של α מושפע בעיקר מעיוות הקוונטיזציה, ולכן המינימום נמצא קרוב מאד ל- $\alpha = 1$. עבור עיוות ערוץ גבוה (b), משתנה מיקומו של המינימום וניתן לשפר באופן משמעותי את ביצועי המערכת ע"י שימוש בטכניקת הכיווץ.

4.3.1 קוונטיזר סקלרי עם כיווץ ליניארי

נסתכל על קוונטיזר סקלרי עם כיווץ ליניארי הפועל בתנאי ערוץ בינארי סימטרי. העיוות הכולל (2.17) עבור מקרה זה הוא:

$$D_{\text{Total}}(\alpha) = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi Q \pi^T)_{ij} \int_{\alpha_{\tau_i}}^{\alpha_{\tau_{i+1}}} (x - \alpha \phi_j)^2 \cdot f_x(x) \cdot dx \quad (4.2)$$

כאשר $\tau_i, i = 0, 1, \dots, N$ הן רמות-ההחלטה של הקוונטיזר, ומוסכם כי $\tau_0 = -\infty$ ו- $\tau_N = +\infty$. נניח כי פונקציות צפיפות ההסתברות $f_x(x)$ מקיימת את התנאי: $[\log f_x(x)]'' \leq 0$, כלומר הלוגריתם של הפונקציה הוא קעור (log-concave). עבור מקורות מסוג זה, למשל: גאוס, לפלסי ואחיד, הפונקציה $D_{\text{Total}}(\alpha)$ היא קמורה וקיים מינימום יחיד לפונקציה בנקודה $\alpha = 1$ [F164], כאשר אין שגיאות בערוץ $q = 0$.

בנספח ב' (B.23), מחושבים הערכים העצמיים והוקטורים העצמיים של מטריצת הערוץ Q עבור ערוץ בינארי סימטרי - $Q = V \Lambda V^T$. למטריצה Q (עבור N רמות ייצוג ו- L סיביות) קיימים $L+1$

ערכים עצמיים שונים $m = 0, 1, \dots, L$, $(1-2q)^m$, כל אחד בריבוי $\binom{L}{m}$.

$$\begin{aligned} D_{\text{Total}}(\alpha) &= \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (\pi V \Lambda V^T \pi^T)_{ij} \int_{\alpha_{\tau_i}}^{\alpha_{\tau_{i+1}}} (x - \alpha \phi_j)^2 \cdot f_x(x) \cdot dx = \\ &\Leftrightarrow \text{trace}\{AB\} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} A_{ij}^T B_{ij} \\ &= \text{trace}\{\pi V \Lambda V^T \pi^T \Delta(\alpha)\} = \\ &\Leftrightarrow \text{trace}\{AB\} = \text{trace}\{BA\} \\ &= \text{trace}\{\Lambda V^T \pi^T \Delta(\alpha) \pi V\} \end{aligned} \quad (4.3)$$

כאשר:

$$\{\Delta(\alpha)\}_{ij} = \int_{\alpha_{\tau_i}}^{\alpha_{\tau_{i+1}}} (x - \alpha \phi_j)^2 \cdot f_x(x) \cdot dx \quad (4.4)$$

הפונקציה $D_{\text{Total}}(\alpha)$ תלויה בהסתברות השגיאה בערוץ q . נתאר עובדה זו מפורשות ע"י הסימון $D_{\text{Total}}(\alpha, q)$. הנגזרת השנייה של $D_{\text{Total}}(\alpha, q)$ לפי α היא:

$$\frac{\partial^2}{\partial \alpha^2} D_{\text{Total}}(\alpha, q) = \text{trace}\{\Lambda V^T \pi^T \Delta''(\alpha) \pi V\} \quad (4.5)$$


כאשר $\Delta''(\alpha)$ מסמן גזירה של האיברים במטריצה. כאמור, עבור $q = 0$, הגזרת השנייה לפי α היא חיובית לכל α . משיקולי רציפות, הגזרת השנייה ממשיכה להיות חיובית גם עבור ערכים קטנים של שגיאות בערוץ q , ולכן מובטח מינימום יחיד גם עבור ערכי q קטנים. בדוגמאות המספריות המוצגות בהמשך הפרק ניתן לראות כי קיים מינימום יחיד גם בהסתברויות שגיאה של $q = 10^{-2}$.

4.4 דוגמאות מספריות

4.4.1 קוונטיזר סקלרי מותאם לפילוג לפלס

נבחן קוונטיזר סקלרי בן 4 סיביות, לא אחיד, המותאם לפילוג לפלס [Ja84, סעיף 4.4.1]. בציר 4.6 מתואר העיוות הכולל כפונקציה של α עבור קצבי שגיאה שונים בערוץ. הגרף מנורמל לשגיאת הקוונטיזציה.

Normalized Total Distortion (dB)



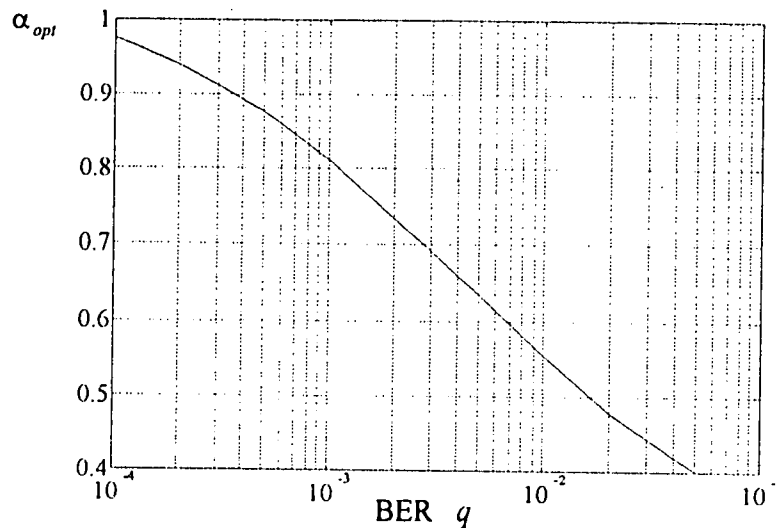
ציר 4.6 - העיוות הכולל בקוונטיזר סקלרי עם כיווץ ליניארי בן 4 סיביות המותאם לפילוג לפלס. העיוות מנורמל לעיוות הקוונטיזציה. פרמטר q - קצב השגיאות בערוץ

Fig. 4.6 - Total Distortion for a 4-bit Scaled Laplacian-PDF-optimized Scalar Quantizer. Distortion is normalized to the Quantization Distortion.

Parameter q - Channel Bit Error Rate

ניתן להבחין בשיפור בביצועים כתוצאה מכיווץ הקוונטיזר, כאשר השיפור היחסי גדל עם עליית קצב השגיאות בערוץ. בנוסף, הכיווץ נעשה משמעותי יותר עם גידול קצב השגיאות בערוץ. לדוגמה, עבור הסתברות שגיאה של $5 \cdot 10^{-3}$ ניתן להשיג שיפור של כ-2dB עבור $\alpha_{opt} \approx 0.63$. לעומת הקוונטיזר ללא כיווץ (עיוות מנורמל של 6dB במקום 8dB). גרף העיוות הוא שטוח בסביבת המינימום כך שידיעה מדויקת של מיקומו איננה הכרחית. לדוגמה, עבור $q = 5 \cdot 10^{-3}$, שימוש בגורם $\alpha_{opt} \approx 0.55$ (האופטימלי ל- $q = 10^{-2}$) יתן רווח של כ-1.5dB מתוך כ-2dB שנותן הגורם המתאים.

בציור 4.7 מתואר גורם הכיווץ האופטימלי כפונקציה של קצב השגיאות בערוץ.




ציור 4.7 - גורם הכיווץ האופטימלי בקוונטיזר סקלרי בן 4 סיביות המותאם לפילוג לפלס

Fig. 4.7 - Scaling Factor for a 4-bit Laplacian-PDF-Optimized Scaled Scalar Quantizer

ניתן לראות כי הכיווץ נעשה משמעותי יותר עם העליה בקצב השגיאות בערוץ. השתנות α_{opt} כפונקציה של הסתברות השגיאה q היא חלקה ובמימוש ניתן לשמור מספר מועט של נקודות בטבלה.

הרווח המתקבל כתוצאה מכיווץ הקוונטיזר כפונקציה של הסתברות השגיאה q , בהשוואה לביצועי COVQ, מופיע בציור 4.8.



ציור 4.8 - הרווח בביצועים עבור קוונטיזר סקלרי בן 4 סיביות המותאם לפילוג לפלס עם כיווץ ליניארי (SVQ) בהשוואה לתכן אופטימלי (COVQ)

Fig. 4.8 - Performance gain for a 4-bit Laplacian-PDF-Optimized Scaled Scalar Quantizer (SVQ) Compared with a Channel Optimized Vector Quantizer (COVQ)

ניתן להבחין בציור כי הקוונטיזר המוצע מסוג SVQ, מביא לרווח בביצועים הקרוב לרווח מתכן מותאם לערוץ. למשל עבור $q = 10^{-2}$ משיג ה-SVQ רווח ביצועים של כ-3dB מתוך רווח של כ-3.5dB המושג עידי ה-COVQ. מצד שני מתאפיין כאמור ה-SVQ בפשטות תכן ובדרישות נמוכות בהרבה בזיכרון הנדרש במימוש.


4.4.2 קוונטיזר סקלרי מותאם לפילוג גאוסי מוכלל

נתבונן כעת בפילוג גאוסי מוכלל (Generalized Gaussian Distribution) [C185, סעיף 4.4.1] עם סטיית תקן השווה לאחד.

$$p(x) = \frac{r}{2} \frac{\Gamma(3/r)^{\frac{1}{2}}}{\Gamma(1/r)^{\frac{3}{2}}} \exp \left[- \left(\frac{\Gamma(3/r)}{\Gamma(1/r)} \right)^{\frac{r}{2}} \cdot x^r \right] \quad (4.6)$$

כאשר $\Gamma(\cdot)$ היא פונקציית גאמה ו- r פרמטר. עבור $r \rightarrow 0$ מתקרבת צפיפות הסתברות להיות מרוכזת באפס, עבור $r = 1$ המקור הוא מקור לפלסי, $r = 2$ מקור גאוסי ועבור $r \rightarrow \infty$ פילוג ההסתברות שואף לפילוג האחיד.

בציור 4.9 מופיע הרווח בביצועי קוונטיזציה סקלרי מותאם לפילוג (עבור ערכי r שונים) כתוצאה מכיווץ ליניארי (SVQ) בהשוואה לקוונטיזציה מסוג COVQ.



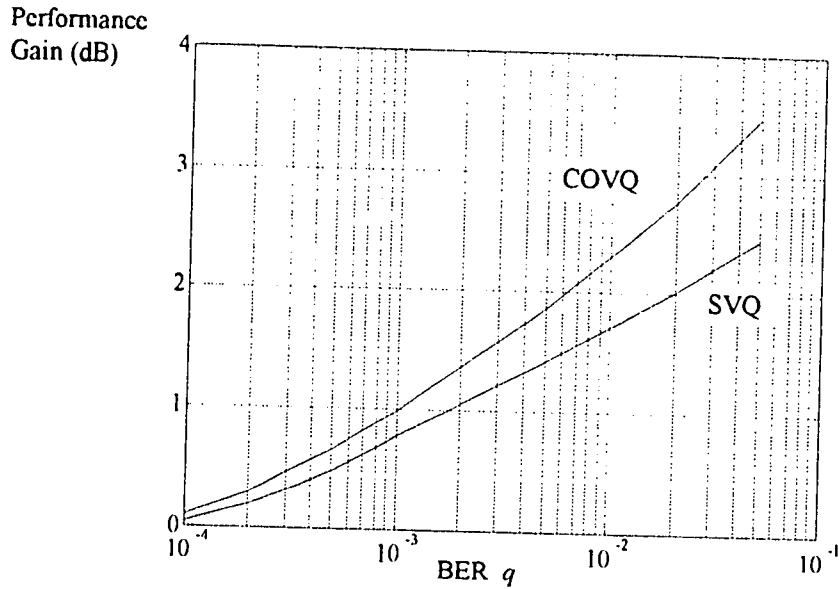
ציור 4.9 - הרווח בביצועים עבור קוונטיזציה סקלרי בן 4 סיביות המותאם לפילוג גאומטרי מוכלל עם פרמטר r עם כיווץ ליניארי (SVQ) בהשוואה לקוונטיזציה אופטימלי לתנאי הערוץ COVQ

Fig. 4.9 - Performance gain for a 4-bit Generalized-Gaussian-PDF-Optimized Scaled Scalar Quantizer (SVQ) compared with Channel Optimized Vector Quantizer (COVQ). r Parameter of the Generalized-Gaussian PDF

ניתן לראות שככל שצפיפות ההסתברות מתרכזת סביב האפס (r הולך וקטן) עולה הרווח המושג בכיווץ ליניארי. הסיבה לתופעה זו היא ההבדלים ברעש ההעמסה (Overload). כיווץ הקוונטיזציה לצורך הקטנת עיוות הערוץ מצמצם את הכיסוי של הקוונטיזציה ומגדיל את רעש ההעמסה. עבור מקורות צפופים, השפעת זנבות הפילוג קטנה יותר, ורעש ההעמסה משתנה באיטיות יחסית עם כיווץ הקוונטיזציה. גורם הכיווץ האופטימלי α_{opt} הוא קטן יותר והרווח גדול יותר. תכן הקוונטיזציה האופטימלי (COVQ) מאפשר עיוות שונה במרכז פונקציית ההסתברות ובזנבות, ולכן הרווח בשימוש ב-COVQ יחסית ל-SVQ גדול יותר עבור פונקציית ההסתברות עם זנבות משמעותיים יותר, כדוגמת המקור האחיד.

4.4.3 קוונטייזר וקטורי מותאם לפילוג גאוס

נתבונן בקוונטייזר וקטורי בעל 256 וקטורים מייצגים (8 סיביות), בקצב של 2 סיביות לדגימה (4 דגימות בוקטור ייצוג), שתואר בציור 3.3. בציור 4.10 מופיע הרווח המתקבל כתוצאה מכיוון הקוונטייזר כפונקציה של הסתברות השגיאה, q , בהשוואה לביצועי COVQ.



ציור 4.10 - הרווח בביצועים עבור קוונטייזר וקטורי בן 8 סיביות (2 סיביות לדגימה) המותאם לפילוג גאוס-מרקוב (מקדם מתאם 0.5) עם כיוון ליניארי (SVQ) בהשוואה לתכן אופטימלי (COVQ)

Fig. 4.10 - Performance gain for an 8-bit (2 bit/sample) Scaled Vector Quantizer (SVQ) designed for a Gauss-Markov source (correlation 0.5) Compared with a Channel Optimized Vector Quantizer (COVQ)

גם במקרה זה ניתן לראות כי הקוונטייזר עם כיוון ליניארי נותן חלק נכבד מן הרווח שהיה ניתן להשיג בתכן אופטימלי מלא. עבור הסתברות שגיאה של $q = 10^{-2}$ נותן ה-SVQ שיפור של כ-1.7dB בביצועים. שיפור נוסף של כ-0.6dB היה מושג ע"י COVQ במחיר גבוה בהרבה במימוש.

4.5 סיכום

בפרק זה הצגנו שיטה תת-אופטימלית לשיפור ביצועי קוונטייזר וקטורי תחת שגיאות ערוץ. המוטיבציה לשימוש בטכניקות תת-אופטימליות היא סיבוכיות התכן ומחיר המימוש של התכן האופטימלי. המימוש המוצע מבוסס על קוונטייזר המתוכנן ללא התחשבות בשגיאות ערוץ, ובכיוון ליניארי של מבנה הקוונטייזר כפונקציה של קצב השגיאות בערוץ. ראינו כי עבור קוונטייזר סקלרי אופטימלי לפילוג המקיים את תנאי ה- \log -concave, מובטח מינימום יחיד עבור הסתברויות שגיאה נמוכות בערוץ.

בדוגמאות מספריות ראינו כי ניתן להשיג רווח נאה בביצועים, יחסית לקוונטייזר שלא מתחשב בשגיאות הערוץ. מצד שני, פשטות התכן והמימוש באות על חשבון הרעה בביצועים יחסית לתכן האופטימלי. בדוגמאות שנבחנו ראינו כי הרעה זו היא סבירה ויש למתכנן מקום לשיקול דעת האם לאמץ את השיטה האופטימלית היקרה או לוותר מעט בביצועים ולבחור את השיטה הזולה הרבה יותר.

פרק 5 - האופטימליות של הקוד-הבינארי-הטבעי עבור קוונטייזר סקלרי אחיד ומקור אחיד (תחת ערוץ בינארי סימטרי)

5.1 מבוא

בפרק המבוא תיארנו את החשיבות שבשיבוץ יעיל של מילות קוד לרמות-ייצוג. ראינו גם כי עבור קוונטייזר בעל N רמות ייצוג, מספר השיבוצים האפשריים, M , איננו מאפשר חיפוש ממצה (Exhaustive Search) למציאת השיבוץ האופטימלי, אף עבור קוונטייזר עם מספר רמות לא רב. בפרק זה נוכיח, בצורה עקיפה, כי הקוד הבינארי הטבעי (Natural Binary Code - NBC) הוא השיבוץ האופטימלי של מילות קוד לרמות הייצוג של קוונטייזר סקלרי אחיד, כאשר מקור האות הוא אחיד והערוץ הוא בינארי סימטרי (Binary Symmetric Channel - BSC). כמו-כן ננסה להסביר מדוע הפתרון "המתבקש" של שיבוץ בקוד Gray איננו אופטימלי. ההוכחה מופיעה בשלמותה בנספח ב', כאשר בפרק זה נביא את תקציר ההוכחה. תוצאה דומה הוצגה בעבר ע"י [Cr69] ובמקביל ע"י [Mc92] McLaughlin. ההוכחה המוצגת כאן הנה קצרה ופשוטה יותר. בנוסף, הרחבנו את דרך ההוכחה לחסמים המוצגים בפרק 6. חסמים אלו נותנים מידע על מקרים מורכבים יותר: קוונטייזרים וקטוריים וסקלריים כלליים, מקורות כלליים וערוצים חסרי זיכרון נוספים.

5.2 השוואה לקוד גריי (Gray)

עבור הערוץ הבינארי הסימטרי, בהסתברויות שגיאה נמוכות, מאורע של שגיאה בסיבית אחת הוא שכיח מאד יחסית למאורעות של שגיאה בשתי סיביות ומעלה. על מנת להקטין את העיוות כתוצאה משגיאות ערוץ, יש לשבץ מילות קוד הנבדלות זו מזו בסיבית בודדת לרמות קרובות ככל האפשר, מבחינת מרחק אוקלידי. קוד Gray [Ja84] (סעיף 4.9.1) מאופיין בכך שכל שתי רמות שכנות נבדלות בסיבית אחת בלבד (מאידך, קיימות גם רמות רחוקות אשר נבדלות בסיבית אחת). קוד זה נראה, לכאורה, מתאים לפתרון לבעיית השיבוץ במקרה זה, אך נראה שאין הדבר כך.

בטבלה 5.1 מתוארים המרחקים הריבועיים (עיוותים) (מנורמלים למרווח בין רמות שכנות) בין רמות הייצוג של קוונטיזר סקלרי אחיד בן $L = 3$ סיביות. כמו-כן רשום הקוד הבינארי הטבעי (NBC - Natural Binary Code) לכל רמת ייצוג, כאשר עיוותים הנגרמים כתוצאה משגיאה בסיבית אחת מסומנים בקו תחתי.

Code		000	001	010	011	100	101	110	111
	Level	-4	-3	-2	-1	0	1	2	3
000	-4	0	<u>1</u>	<u>4</u>	9	<u>16</u>	25	36	49
001	-3	<u>1</u>	0	1	<u>4</u>	9	<u>16</u>	25	36
010	-2	<u>4</u>	1	0	<u>1</u>	4	9	<u>16</u>	25
011	-1	9	<u>4</u>	<u>1</u>	0	1	4	9	<u>16</u>
100	0	<u>16</u>	9	4	1	0	<u>1</u>	<u>4</u>	9
101	1	25	<u>16</u>	9	4	<u>1</u>	0	1	<u>4</u>
110	2	36	25	<u>16</u>	9	<u>4</u>	1	0	<u>1</u>
111	3	49	36	25	<u>16</u>	9	<u>4</u>	<u>1</u>	0

טבלה 5.1 - מרחקים ריבועיים מנורמלים בין רמות הייצוג בקוונטיזר סקלרי אחיד. לכל רמת ייצוג מסומן השיבוץ בקוד הבינארי הטבעי.

עיוותים הנגרמים כתוצאה משגיאה בסיבית אחת מצוינים ע"י קו-תחתי.

Table 5.1 - Normalized squared distances among representing-levels of a uniform scalar quantizer. Each level is assigned with its Natural-Binary-Code codeword.

Distortions due to a single-bit errors are underlined.

העיוות הממוצע כתוצאה משגיאה (של סיבית אחת) במקרה זה הוא :

$$.(8 \cdot 1 + 8 \cdot 4 + 8 \cdot 16) / 24 = 7$$

נבחן קוד Gray בן L סיביות ($N = 2^L$ רמות ייצוג). עבור כל רמת ייצוג (פרט לקצוות) קיימת סיבית אחת, אשר שגיאה בה תגרור שחזור של רמת ייצוג שכנה כלפי מעלה. קיימת גם סיבית אחרת, אשר שגיאה בה תגרור שחזור של רמת ייצוג שכנה כלפי למטה. שגיאה בשאר $L-2$ הסיביות במילת הקוד יגרמו לשחזור של רמות ייצוג רחוקות יותר. לדוגמה, הקודים של רמות הייצוג בקצוות (000...0 ו-100...0) נבדלים ביניהם בסיבית אחת.

בטבלה 5.2 רשום קוד Gray לכל רמת ייצוג. עיוותים הנגרמים כתוצאה משגיאה בסיבית אחת מסומנים בקו תחתי. יש לשים לב כי במקרה זה, עבור כל רמת ייצוג, שגיאה בשתיים מתוך שלוש הסיביות יגרמו לשחזור רמת-ייצוג שכנה.

Code		000	001	011	010	110	111	101	100
	Level	-4	-3	-2	-1	0	1	2	3
000	-4	0	<u>1</u>	4	<u>9</u>	16	25	36	<u>49</u>
001	-3	<u>1</u>	0	<u>1</u>	4	9	16	<u>25</u>	36
011	-2	4	<u>1</u>	0	<u>1</u>	4	<u>9</u>	16	25
010	-1	<u>9</u>	4	<u>1</u>	0	<u>1</u>	4	9	16
110	0	16	9	4	<u>1</u>	0	<u>1</u>	4	<u>9</u>
111	1	25	16	<u>9</u>	4	<u>1</u>	0	<u>1</u>	4
101	2	36	<u>25</u>	16	9	4	<u>1</u>	0	<u>1</u>
100	3	<u>49</u>	36	25	16	<u>9</u>	4	<u>1</u>	0

טבלה 5.2 - מרחקים ריבועיים מנורמלים בין רמות הייצוג בקוונטיזר סקלרי אחיד.

לכל רמת ייצוג מסומן השיבוץ בקוד Gray.

עיוותים הנגרמים כתוצאה משגיאה בסיבית אחת מצוינים ע"י קו-תחתי.

Table 5.2 - Normalized squared distances among representing-levels of a uniform scalar quantizer. Each level is assigned with its Gray-code codeword.

Distortions due to a single-bit errors are underlined.

העיוות הממוצע כתוצאה משגיאה (של סיבית אחת) במקרה זה הוא:

$$(14 \cdot 1 + 6 \cdot 9 + 2 \cdot 25 + 2 \cdot 49) / 24 = 9$$

עיקר העיוות נגרם כתוצאה מכך שבקוד Gray רמות הייצוג הרחוקות (3,+4) ו-(2,+3) נבדלות בסיבית אחת בלבד.

בדוגמה זו ניתן לראות כי עיוות גבוה יותר נגרם כתוצאה מקוד Gray בהשוואה לקוד הבינארי הטבעי. כעת נפנה להוכחה כי השיבוץ האופטימלי הוא הקוד הבינארי הטבעי. תוצאה זו תהיה

$$0 \leq q < \frac{1}{2}$$

5.3 תקציר ההוכחה

נתאר כעת בקצרה את ההוכחה לשיבוץ האופטימלי. כאמור, ההוכחה במלואה מופיעה בנספח ב'. ההוכחה מבוססת על החלפת הבעיה הקומבינטורית בבעיית אופטימיזציה רציפה. כפי שניווכח לדעת, במקרה זה (קוונטיזר סקלרי אחיד, מקור אות אחיד וערוץ בינארי סימטרי) האופטימום בשתי הבעיות מתלכד.

שלבי ההוכחה הם:

1. תיאור הבעיה ודרך למציאת חסמים ע"י מעבר לבעיית אופטימיזציה רציפה.
2. פתרון הבעיה הרציפה ע"י כופלי לגרנז' והגדרת החסמים.
3. הוכחת התלכדות החסם התחתון עם ביצועי הקוד הבינארי הטבעי.

5.3.1 תיאור הבעיה ומעבר לרצף

נתבונן בקוונטיזר סקלרי בן L סיביות ו- $N = 2^L$ רמות ייצוג. רמות הייצוג מתוארות בציר 3.7. נתאר את רמות הייצוג בוקטור עמודה, כמו ב-(3.11):

$$\underline{\rho} = \begin{bmatrix} \rho_0 \\ \rho_1 \\ \vdots \\ \rho_i \\ \vdots \\ \rho_{N-1} \end{bmatrix} = \frac{2}{N} \begin{bmatrix} -N/2 + 1/2 \\ 1 - N/2 + 1/2 \\ \vdots \\ i - N/2 + 1/2 \\ \vdots \\ N/2 - 1 + 1/2 \end{bmatrix} \quad (5.1)$$

ביטוי כללי לעיוות הערוץ הוא, עפ"י (2.15):

$$D_c = \text{trace}\{P \pi Q_N \pi^T D\} \quad (5.2)$$

במקרה הנוכחי ניתן להציב את הגדלים הבאים:

$$\begin{aligned} P &= \frac{1}{N} I \\ \{D\}_{ij} &= (\underline{\rho}_i - \underline{\rho}_j)^2 \\ \{Q_N\}_{ij} &= q^{H(i,j)} (1-q)^{L-H(i,j)} \end{aligned} \quad (5.3)$$

כאשר I היא מטריצת היחידה, $L = \log_2 N$ - מספר הסיביות, q - היא הסתברות השגיאה בערוץ ו- $H(i, j)$ הוא מרחק Hamming בין הייצוג הבינארי של i ו- j .

הצבת הגדלים ב-(5.2) ושימוש בזהויות אלגבריות (ראה B.3) מביא את ביטוי עיוות הערוץ לצורה הבאה:

$$D_c = \frac{2}{N} (\underline{z}^T \underline{z} - \underline{z}^T Q_N \underline{z}) \quad (5.4)$$

כאשר הוקטור $\underline{z} = \pi \underline{\rho}$ הוא פרמוטציה של וקטור רמות הייצוג. על מנת למצוא חסם עליון וחסם תחתון לעיוות הערוץ מעל כל שיבוצי מילות הקוד האפשריים, ניתן לאפשר לאיברי \underline{z} להיות רציפים, תוך שמירת שני המומנטים הראשונים. בכך נעבור מבעיית אופטימיזציה דיסקרטית מעל $N!$ אפשרויות לבעיית אופטימיזציה רציפה. יש לשים לב כי עבור כל הפרמוטציות האפשריות מתקיים:

א. סכום איברי \underline{z} קבוע ושווה לאפס.

ב. הנורמה של הוקטור קבועה: $\underline{z}^T \underline{z} = \underline{\rho}^T \pi^T \cdot \pi \underline{\rho} = \underline{\rho}^T \underline{\rho} = \frac{(N+1)(N-1)}{3N} = k^2$

החסמים ימצאו ע"י פתרון בעיית האופטימיזציה הבאה:

$$\begin{aligned} \min / \max_{\underline{z}} \quad & f(\underline{z}) = \underline{z}^T \underline{z} - \underline{z}^T Q_N \underline{z} \\ \text{s.t.} \quad & \underline{1}^T \underline{z} = 0 \\ & \underline{z}^T \underline{z} = \underline{\rho}^T \underline{\rho} = k^2 \end{aligned} \quad (5.5)$$

כאשר $\underline{1}$ הוא וקטור N -ממדי שכל איבריו הם אחד. האיבר הראשון בפונקציית המטרה $\underline{z}^T \underline{z}$ הוא, כאמור, קבוע. ניתן להוציא אותו מן הבעיה ונקבל:

$$\begin{aligned} \max / \min_{\underline{z}} \quad & f(\underline{z}) = \underline{z}^T Q_N \underline{z} \\ \text{s.t.} \quad & \underline{1}^T \underline{z} = 0 \\ & \underline{z}^T \underline{z} = \underline{\rho}^T \underline{\rho} = k^2 \end{aligned} \quad (5.6)$$

5.3.2 פתרון בעיית האופטימיזציה באמצעות כופלי לגרנג'

לפני שניגש לפתרון נשתמש בתכונת הסימטריה של מטריצת הערוץ Q_N . למטריצה יש לכסון יוניטרי:

$$Q_N = V \cdot \Lambda \cdot V^T \quad V \cdot V^T = I \quad (5.7)$$

מכיוון שמטריצת הערוץ Q_N מייצגת הסתברויות, סכום כל השורות שלה הוא אחד כלומר $Q_N \underline{1} = \underline{1}$. נניח לכן כי הערך העצמי הראשון של המטריצה $\lambda_0 = 1$ והוקטור העצמי המתאים

$$\underline{v}_0 = \frac{1}{\sqrt{N}} \underline{1} \quad (V \text{ של } V)$$

נפתור כעת את (5.6) ע"י כופלי לגרנג' μ_1, μ_2 :

$$L(\underline{z}, \mu_1, \mu_2) = \underline{z}^T Q_N \underline{z} + \mu_1 (\underline{z}^T \underline{z} - k^2) + \mu_2 (\underline{1}^T \underline{z}) \quad (5.8)$$

פתרון הבעיה מוביל ל- N המשוואות הבאות, המופיעות בנספח ב' (B.17):

$$\left[\lambda_i - (\underline{\xi}^T \Lambda \underline{\xi}) \right] \cdot \xi_i = 0, \quad i = 0, 1, 2, \dots, N-1 \quad (5.9)$$

כאשר הוקטור $\underline{\xi}$ מוגדר ע"י $\underline{\xi} = \frac{1}{k} V^T \underline{z}$. המשוואה הראשונה, זו המתאימה ל- $\lambda_0 = 1$, נכונה

תמיד מכיוון שהאיבר הראשון בוקטור שווה לאפס (B.12): $\xi_0 = 0$.

נניח כעת כי לערך עצמי מסוים של Q_N יש ריבוי m : $\lambda_l = \lambda_{l+1} = \dots = \lambda_{l+m-1} = \lambda$. פתרון המתאים לערך עצמי זה הוא כדלקמן:

איברי $\underline{\xi}$ שאינם מתאימים לערך העצמי λ שווים לאפס: $\xi_i = 0 \quad i \neq l, l+1, \dots, l+m-1$

איברי $\underline{\xi}$ המתאימים לערך העצמי λ נקבעים כך שיקיימו את הדרישה: $\underline{\xi}^T \underline{\xi} = 1$ (B.12a). קיום

הדרישה מבטיח כי $\underline{\xi}^T \Lambda \underline{\xi} = \lambda$.

הוקטור המקורי $\underline{z} = k \cdot \underline{w} = k \cdot V \underline{\xi}$ מורכב מקומבינציה ליניארית של עמודות V ולכן של

וקטורים עצמיים של Q_N , אלו המתאימים לערך העצמי λ . הצבת \underline{z} בפונקצית המטרה של הבעיה המקורית (5.5) תיתן:

$$\begin{aligned} f(\underline{z}) &= k^2 - k^2 \underline{\xi}^T V^T \cdot V \Lambda V^T \cdot V \underline{\xi} = \\ &= k^2 (1 - \underline{\xi}^T \Lambda \underline{\xi}) = k^2 (1 - \lambda) \end{aligned} \quad (5.10)$$

המקסימום יתקבל עבור הערך העצמי λ הקטן ביותר (פרט ל- $\lambda_0 = 1$). המינימום יתקבל עבור

הערך העצמי λ הגדול ביותר (פרט ל- $\lambda_0 = 1$).

בנספח ב' מתואר חישוב הערכים העצמיים והוקטורים העצמיים של המטריצה Q_N באופן רקורסיבי (עבור הסתברויות שגיאה בערוץ המקיימות $q < 0.5$). עבור קוונטיזר בן סיבית אחת, $L=1$, הוקטורים העצמיים והערכים העצמיים המתאימים הם:

$$\begin{bmatrix} 1 \\ 1 \end{bmatrix}, 1 \quad ; \quad \begin{bmatrix} 1 \\ -1 \end{bmatrix}, 1-2q \quad (5.11)$$

נניח כי y הוא וקטור עצמי של המטריצה Q_N (L סיביות) המתאים לערך עצמי α . אזי ניתן לבנות ממנו (ראה B.22) שני זוגות של וקטורים עצמיים וערכים עצמיים עבור המטריצה Q_{2N} ($L+1$ סיביות). וקטור עצמי אחד מתקבל ע"י ביצוע שכפול והוקטור העצמי השני ע"י שכפול שלילי:

$$\begin{bmatrix} y \\ y \end{bmatrix}, \alpha \quad ; \quad \begin{bmatrix} y \\ -y \end{bmatrix}, (1-2q)\alpha \quad (5.12)$$

מהסתכלות על תהליך הבניה הרקורסיבית של מטריצת הלכסון (B.23), ניתן להבחין כי היא מטריצת Walsh-Hadamard המופיעה בשטחי עיבוד תמונה [CI85 סעיף 7.3]. כללית יש למטריצה Q_N (L סיביות) $L+1$ ערכים עצמיים שונים $m = 0, 1, \dots, L$, $(1-2q)^m$, כל

אחד בריבוי $\binom{L}{m}$.

נציב את הערכים העצמיים ב-(5.10) כאשר הערך העצמי הגדול ביותר פרט ל-1 הוא $1-2q$, והערך העצמי הקטן ביותר הוא $(1-2q)^L$. בצורה זו נקבל את החסמים על העיוות כתוצאה משגיאות ערוץ:

$$\frac{2(N+1)(N-1)}{3N^2} \cdot 2q \leq D_c \leq \frac{2(N+1)(N-1)}{3N^2} \left[1 - (1-2q)^L \right] \quad (5.13)$$

היחס בין החסמים עבור הסתברויות שגיאה קטנות בערוץ הוא:

$$\lim_{q \rightarrow 0} \frac{[1 - (1-2q)^L]}{2q} = L \quad (5.14)$$

כלומר, היחס בין החסמים גדל ליניארית עם מספר הסיביות.

בפרק הבא, בסעיף 6.3.1, קיים חישוב מספרי של החסמים הללו עבור קוונטיזר אחד בן $L = 4$ סיביות. כמו-כן נעשית שם השוואה בין החסמים לבין תוצאות 10,000 שיבוצים אקראיים (מתוך כ- $2 \cdot 10^{13} \approx 16!$). המרחק בין החסמים הוא $10 \cdot \log_{10} 4 = 6\text{dB}$. החסם התחתון מושג ע"י השיבוץ הבינארי הטבעי והחסם העליון רחוק אך כ-0.5dB מן השיבוץ הגרוע ביותר שנתגלה. המסקנה היא שבמקרה זה ניתן לקבל רווח של כ-5.5 – 6dB ע"י בחירת שיבוץ טוב לעומת בחירה גרועה.

5.3.3 הוכחת התלכדות ביצועי הקוד הבינארי הטבעי עם החסם התחתון

בסעיף הקודם הוכחנו כי המינימום לבעיית האופטימיזציה הרציפה מתקבל עבור וקטורים עצמיים של המטריצה Q_N המתאימים לערך העצמי $1 - 2q$. נראה כעת כי הוקטור $\underline{z} = \underline{\rho}$, המתאים לקוד הבינארי הטבעי, הוא אכן וקטור עצמי כזה. וקטור עצמי המתאים לערך העצמי $1 - 2q$ נבנה ע"י $L - 1$ שכפולים ושכפול-שלילי אחד (5.12). כאשר השכפול הראשון הוא השכפול שלילי מתקבל הוקטור:

$$\underline{y}_1 = [1 \ -1 \ 1 \ -1 \ 1 \ -1 \ \dots \ \dots \ 1 \ -1]^T \quad (5.15)$$

איברי הוקטור הם $(-1)^i$, $i = 0, 1, \dots, N - 1$.
כאשר השכפול השני הוא השלילי מתקבל הוקטור:

$$\underline{y}_2 = [1 \ 1 \ -1 \ -1 \ 1 \ 1 \ \dots \ \dots \ -1 \ -1]^T \quad (5.16)$$

איברי הוקטור הם $(-1)^{\lfloor i/2 \rfloor}$, $i = 0, 1, \dots, N - 1$ כאשר $\lfloor i/2 \rfloor$ מתאר חילוק שלמים ללא שארית. הוקטור העצמי האחרון המתאים לערך העצמי $1 - 2q$ נבנה כאשר השכפול האחרון הוא שלילי. מתקבל הוקטור:

$$\underline{y}_L = [1 \ 1 \ \dots \ 1 \ 1 \ -1 \ -1 \ \dots \ -1 \ -1]^T \quad (5.17)$$

קיים דמיון בין שיטת הספירה הבינארית לבין הוקטורים העצמיים. איברי וקטור \underline{y}_1 מתנהגים כמו הספרה הבינארית הפחות משמעותית (LSB - Least Significant Bit) בספירה בינארית. איברי הוקטור האחרון, \underline{y}_L מתנהגים כמו הספרה הבינארית המשמעותית ביותר (MSB - Most Significant Bit).

נבנה קומבינציה ליניארית של הוקטורים אשר תשווה לוקטור רמות הייצוג $\underline{\rho}$:

$$\begin{aligned} \underline{z} = \frac{1}{N} \sum_{i=1}^L 2^{i-1} \cdot \underline{v}_i = \frac{1}{N} [-1 \ 1 \ -1 \ 1 \ -1 \ 1 \ \dots \ \dots \ -1 \ 1]^T + \\ + \frac{2}{N} [-1 \ -1 \ 1 \ 1 \ -1 \ -1 \ \dots \ \dots \ 1 \ 1]^T + \\ \vdots \\ + \frac{1}{2} [-1 \ -1 \ \dots \ -1 \ -1 \ 1 \ 1 \ \dots \ 1 \ 1]^T = \underline{\rho} \end{aligned} \quad (5.18)$$

מכיוון ש- $\underline{\rho}$ הוא וקטור עצמי המתאים לערך העצמי $1 - 2q$, הוא מהווה פתרון אופטימלי לבעיית האופטימיזציה הרציפה. וקטור זה מתאים לשיבוץ חוקי של מילות קוד - הקוד הבינארי הטבעי. מכאן שהקוד הבינארי הטבעי הוא השיבוץ האופטימלי. מעניין לציין כי השיבוץ הבינארי הטבעי איננו השיבוץ האופטימלי היחיד. בנספח ב' (B.31) מוצגת בנייה של $L! \cdot 2^L$ שיבוצים שונים בעלי ביצועים זהים לקוד הבינארי הטבעי.

5.4 סיכום

בפרק זה הוכחנו כי השיבוץ הבינארי הטבעי (NBC) הוא שיבוץ אופטימלי עבור קוונטיזר סקלרי אחיד, מקור אחיד וערוץ בינארי סימטרי. דוגמה מספרית מפורטת למקרה הזה ניתן למצוא בהמשך בסעיף 6.3.1. בסעיף 6.3.2 נראה עוד כי השיבוץ הבינארי הטבעי אופטימלי גם עבור בעיה אחרת, דומה, אך השונה מבחינת תנאי הערוץ. ההוכחה כי ה-NBC הוא השיבוץ האופטימלי במקרה הנדון, נעשתה בטכניקה של החלפת בעיית האופטימיזציה הדיסקרטית בבעיה רציפה. שימוש בטכניקה דומה יאפשר לנו למצוא חסמים למקרים כלליים יותר בפרק הבא.

פרק 6 - חסמים על עיוות הערוץ מעל כל שיבוצי הקודים האפשריים (ערוץ סימטרי חסר זיכרון)

6.1 מבוא

בפרקים הקודמים עמדנו על מספרם העצום של השיבוצים האפשריים של מילות קוד לוקטורי-ייצוג בקוונטיזרים וקטוריים. ראינו בפרק 5 כי במקרה המיוחד של קוונטיזר סקלרי אחיד, מקור אחיד וערוץ ביטארי סימטרי, ניתן להצביע על השיבוץ האופטימלי, שהוא הקוד הביטארי הטבעי, וניתן לקבל חסם עליון על ביצועי השיבוץ הגרוע ביותר (5.13).

בפרק זה יתוארו חסמים על עיוות הערוץ מעל כל $N!$ השיבוצים האפשריים של מילות קוד בקוונטיזרים וקטוריים כלשהם. החסמים ניתנים ליישום עבור ערוצים חסרי-זיכרון סימטריים. אין כל הגבלה על מבנה הקוונטיזרים, מידת המרחק ועל מקורות-האות. החסמים יכולים לתת למתכנן מידע כללי על עיוות הערוץ הצפוי במערכת לפני ההחלטה על שיבוץ מסוים. ניתן לעמוד על מרווח-הביצועים שניתן לקבל תוך שינוי השיבוצים ולבחון שיבוץ קיים באמצעות מיקומו בין החסמים.

פיתוח החסמים מופיע בשלמותו בנספח ג', בפרק זה נציג את תקציר הפיתוח בלבד. טכניקת החסימה דומה לטכניקה שהוצגה בפרק 5 בכך שאנו מחליפים את בעיית האופטימיזציה הדיסקרטית בבעיית אופטימיזציה רציפה הניתנת לפתרון בשיטות "קלאסיות". עבור המקרה של קוונטיזר סקלרי אחיד ומקור אחיד מתלכדים החסמים עם התוצאות שהוצגו בפרק 5. בסופו של הפרק ניתנות דוגמאות מספריות עבור קוונטיזרים שונים וערוצים שונים.

6.2 תקציר פיתוח החסמים

בדומה לפרק 5, טכניקת החסימה מבוססת על החלפת בעיית האופטימיזציה הקומבינטורית בבעיית אופטימיזציה רציפה. שלבי הפיתוח הם:

1. הצגת עיוות הערוץ ע"י מטריצה מרחקים משוקללת \hat{D} . \hat{D} מכילה את המידע על המרחקים בין וקטורי הייצוג ואת הסתברויות ההופעה שלהן במקור.

2. החלפת המטריצה \hat{D} בבעיה למטריצה סימטרית אחרת \tilde{D} בעלת התכונה הבאה:

המטריצה \tilde{D} נבנית כך שהווקטור: $\underline{1} = [1 \ 1 \ \dots \ 1]^T$ הוא וקטור עצמי שלה. תכונה זו נדרשת לשלב האחרון של הפיתוח.

3. הרחבת הבעיה הקומבינטורית לבעיה רציפה.

4. פתרון הבעיה הרציפה תוך שימוש בוקטורים העצמיים של המטריצה \tilde{D} ומציאת החסמים.

6.2.1 תיאור הבעיה

לפי (2.15), ביטוי כללי לעיוות הערוץ ניתן ע"י:

$$D_c = \text{trace}\{P \pi Q_N \pi^T D\} \quad (6.1)$$

אנו מניחים כי מטריצת הערוץ Q_N הינה סימטרית. מכיוון שהיא מייצגת הסתברויות, סכום כל שורה שווה לאחד ולכן $\underline{1} = \underline{1} \cdot Q_N$. אין הנחות נוספות על מטריצת ההסתברויות P (אלכסונית) ועל מטריצת המרחקים בין הווקטורים המיצגים D . השיבוץ מתואר ע"י מטריצת הפרמוטציה π .

תוך שימוש בזהויות אלגבריות (C.1) ניתן לאחד את המטריצות P ו- D למטריצה סימטרית אחת \hat{D} - כך שמתקיים:

$$D_c = \frac{1}{2} \text{trace}\{Q_N \pi^T \hat{D} \pi\} \quad (6.2)$$

כאשר $\hat{D} = DP + P^T D^T$ היא מטריצת המרחקים המשוקללת.

6.2.2 שינוי במטריצת המרחקים המשוקללת

הקדמה

בסעיף 6.2.4 נפתור בעיית אופטימיזציה עם אילוצים. אם $\underline{1}$ הוא וקטור עצמי של מטריצת המרחקים המשוקללת, פתרון הבעיה נעשה פשוט יותר והפתרון הוא פונקציה של הערכים העצמיים של מטריצת המרחקים המשוקללת. מסיבה זו, כשלב ראשון, נשנה את בעיית האופטימיזציה כך שמטריצה \tilde{D} תחליף את \hat{D} . הוקטור $\underline{1}$ יהיה וקטור עצמי של המטריצה החדשה \tilde{D} .

בנספח (C.2) מוגדרת מטריצה C_i בגודל $N \times N$ המכילה "1"ים בעמודה ה- i , שאר המטריצה מורכבת מאפסים:

$$C_i = \begin{bmatrix} 0 & 0 & 1 & 0 & & 0 \\ 0 & 0 & 1 & 0 & & 0 \\ 0 & 0 & 1 & 0 & & 0 \\ 0 & \dots & 0 & 1 & 0 & \dots & \dots & 0 \\ 0 & 0 & 1 & 0 & & & & 0 \\ 0 & 0 & 1 & 0 & & & & 0 \\ 0 & 0 & 1 & 0 & & & & 0 \end{bmatrix} \quad \uparrow \quad i\text{-th column} \quad (6.3)$$

מכיוון ש- $\underline{0} = \underline{0} \cdot Q_N$ וכן $\underline{1} = \underline{1} \cdot Q_N$, מטריצה זו מקיימת את התכונה $C_i \cdot Q_N = Q_N \cdot C_i$.

בנספח (C.6) ניתן לראות כי תוספת של מטריצה במבנה צלב: $\alpha(C_i + C_i^T)$, כאשר α סקלר כלשהו, ל-(6.2) גורמת לתוספת קבוע אשר איננו תלוי בשיבוץ, ולכן איננו משנה את מהות הבעיה:

$$\begin{aligned} \frac{1}{2} \text{trace} \{ Q_N \pi^T (\hat{D} + \alpha C_i^T + \alpha C_i) \pi \} &= \\ &= \frac{1}{2} \text{trace} \{ Q_N \pi^T \hat{D} \pi \} + \alpha \end{aligned} \quad (6.4)$$

על מנת שהוקטור $\underline{1}$ יהיה וקטור עצמי של המטריצה \bar{D} , על סכום האיברים בשורה להיות שווה בכל השורות.

תוספת מטריצה במבנה צלב $\alpha(C_i + C_i^T)$ מוסיפה את הסקלר α לסכום כל השורות, פרט לשורה ה- i אשר מקבלת תוספת של $(N+1)\alpha$ לסכום איבריה. סכום השורה ה- i מקבל בכך "יתרון" של

$N\alpha$ לעומת שאר השורות. תוספת המטריצה במבנה הצלב שומרת על הסימטריה של \hat{D} .

בעזרת האלגוריתם הבא אנו מוסיפים למטריצה \hat{D} מטריצות במבנה צלב אשר יביאו את הסכום בכל שורה ושורה להיות שווה לסכום הגדול ביותר. את סכום הסקלרים המתווספים יש לשמור ולדאוג להחסירו מן הביטוי לעיוות.

אלגוריתם להשוואת סכומי האיברים בשורה עבור כל השורות במטריצת המרחקים המשוקללת

אתחול: מטריצת המרחקים המשוקללת $\bar{D} \leftarrow \hat{D} = DP + P^T D^T$
 סכום הסקלרים המתווספים $S \leftarrow 0$

צעד 1: חשב את הסכום S_i של כל השורות במטריצה \bar{D} . $S_i = \sum_{j=0}^{N-1} \bar{D}_{ij}$, $i = 0, 1, \dots, N-1$.

צעד 2: חפש את הסכום המקסימלי וסמן את השורה עם סכום זה ב- k . $S_k = \max_{i=0,1,\dots,N-1} S_i$.

צעד 3: עבור כל שורה $i \neq k$:

הוסף מטריצה במבנה צלב: $\bar{D} \leftarrow \bar{D} + \frac{1}{N} (S_k - S_i) (C_i + C_i^T)$

עדכן את סכום הסקלרים: $S \leftarrow S + \frac{1}{N} (S_k - S_i)$

בסיום האלגוריתם המטריצה הסימטרית \bar{D} מקיימת את התכונה הדרושה $\bar{D} \cdot \underline{1} = \omega_0 \cdot \underline{1}$, כאשר ω_0 הוא הערך העצמי של \bar{D} המתאים לוקטור העצמי $\underline{1}$, ו- S הוא סכום הסקלרים שהתווספו.

עיוות הערוץ כפונקציה של \bar{D} הוא :

$$D_c = \frac{1}{2} \text{trace}\{Q_N \pi^T \bar{D} \pi\} - S \quad (6.5)$$

כאשר S הוא סכום הסקלרים שחושב בצעד 3 של האלגוריתם.

6.2.3 מעבר לבעיית אופטימיזציה רציפה

מטריצת הערוץ Q_N הנה חיובית וסימטרית ולכן ניתן ללכסן אותה לכסון יוניטרי.

$$Q_N = V \cdot \Lambda \cdot V^T \quad V \cdot V^T = I \quad (6.6)$$

מכיוון ש- $\underline{1} = Q_N \cdot \underline{1}$, נוכל לבחור שהערך העצמי הראשון יהיה $\lambda_0 = 1$ והוקטור העצמי (עמודה

ראשונה של המטריצה V) יהיה $\frac{1}{\sqrt{N}} \underline{1}$. עיוות הערוץ מבוטא כעת :

$$\begin{aligned} D_c &= \frac{1}{2} \text{trace}\{V \Lambda V^T \pi^T \bar{D} \pi\} - S = \\ &= \frac{1}{2} \text{trace}\{\pi V \Lambda V^T \pi^T \bar{D}\} - S = \end{aligned} \quad (6.7)$$

המטריצה πV היא מטריצה יוניטרית לכל פרמוטציה π , מכיוון ש-

$$(\pi V)(\pi V)^T = \pi V V^T \pi^T = \pi \pi^T = I$$

איננה משתנה, $\frac{1}{\sqrt{N}} \underline{1}$, איננה משתנה

תחת פרמוטציה. על מנת לקבל את החסמים, נרחיב את המשפחה הדיסקרטית של מטריצות המתקבלות מ- V ע"י פרמוטציה של שורות, למשפחת כלל המטריצות היוניטריות כאשר העמודה הראשונה שלהן זהה למטריצה המקורית. נחפש את המינימום והמקסימום של הביטוי המורחב לעיוות הערוץ ונקבל חסמים על הביצועים מעל כל הפרמוטציות האפשריות. בפתרון בעיית האופטימיזציה ניתן להתעלם מן הקבוע S .

יש לכן לפתור את הבעיה הבאה :

$$\min_U / \max_U \left(\text{trace}\{\Lambda U^T \bar{D} U\} \right) \quad (6.8)$$

כאשר U היא מטריצה יוניטרית, $U U^T = I$, שהעמודה הראשונה שלה היא $\underline{u}_0 = \frac{1}{\sqrt{N}} \underline{1}$.

6.2.4 פתרון בעיית אופטימיזציה הרציפה

בנספח ג' (C.11) ניתנת הוכחה כי המינימום והמקסימום ל-(6.8) מתקיימים כאשר המטריצה U מורכבת מווקטורים עצמיים של \tilde{D} . נסמן את הערכים העצמיים של \tilde{D} ע"י $\omega_i, i = 0, 1, \dots, N-1$ ואת הווקטורים העצמיים המתאימים ע"י $\underline{z}_i, i = 0, 1, \dots, N-1$. כאן עומדת לרשותנו העובדה שהמטריצה \tilde{D} נבנתה כך שהווקטור $\underline{z}_0 = \frac{1}{\sqrt{N}} \underline{1}$ הוא וקטור עצמי שלה והאילוץ על U מתקיים.

ערך פונקצית המטרה ב-(6.8) הוא:

$$\begin{aligned} \text{trace}\{\Lambda U^T \tilde{D} U\} &= \sum_{i=0}^{N-1} \lambda_i \underline{z}_i^T \tilde{D} \underline{z}_i = \sum_{i=0}^{N-1} \lambda_i \omega_i \underline{z}_i^T \underline{z}_i = \\ &= \sum_{i=0}^{N-1} \lambda_i \omega_i \end{aligned} \quad (6.9)$$

עדין נותרה בידינו דרגת החופש של בחירת סדר הערכים העצמיים. פרט ל- λ_0 ו- ω_0 אשר חייבים להיות מזווגים בגלל האילוץ, הרי שאת שאר הערכים העצמיים ניתן לסדר כרצוננו. בנספח מנוצלת העובדה שהמטריצות Q_N ו- \tilde{D} הן סימטריות והווקטור $\underline{1}$ הוא וקטור עצמי שלהן על מנת להראות ש- λ_0 הוא הערך העצמי הגדול ביותר (לפי Perron-Frobenius [La85]). סעיף (15.3) של Q_N ו- ω_0 הוא הערך העצמי הגדול ביותר של \tilde{D} . נסדר את הערכים העצמיים בסדר יורד ונסמן אותם ע"י $\lambda_i, i = 1, 2, \dots, N-1$ וע"י $\omega_i, i = 1, 2, \dots, N-1$. הערך המקסימלי יתקבל כאשר נבצע את הכפל ב-(6.9) לפי סדר זה. הערך המינימלי יתקבל כאשר נהפוך את הסדר באחת הקבוצות. כלומר:

$$\lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \omega_{N-i} \leq \text{trace}\{\Lambda U^T \tilde{D} U\} \leq \lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \omega_i \quad (6.10)$$

כאשר $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_{N-1}$ וכן $\omega_1 \geq \omega_2 \geq \dots \geq \omega_{N-1}$. $\lambda_0 = 1$ הוא הערך העצמי של המטריצה Q_N המתאים לווקטור העצמי $\underline{1}$ ו- ω_0 הוא הערך העצמי של \tilde{D} המתאים לאותו וקטור עצמי. נציב את (5.11) ב-(5.8) ונקבל את החסמים על העיוות כתוצאה משגיאות ערוץ:

$$\frac{1}{2} \left(\lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \omega_{N-i} \right) - S \leq D_C \leq \frac{1}{2} \left(\lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \omega_i \right) - S \quad (6.11)$$

לסיכום, מציאת החסמים נעשית לפי ה-"מתכון" הבא (צעדים 1-3 הם עפ"י האלגוריתם שתואר בסעיף 6.2.2):

אלגוריתם למציאת החסמים על עיוות הערוץ מעל כל השיבוצים האפשריים

נתונים: מטריצת הערוץ Q (2.11).

מטריצת המרחקים D (2.14)

מטריצת ההסתברויות P (2.14)

אתחול: מטריצת המרחקים המשוקללת $\bar{D} \leftarrow \hat{D} = DP + P^T D^T$

סכום הסקלרים המתווספים $S \leftarrow 0$

צעד 1: חשב את הסכום S_i של כל השורות במטריצה \bar{D} . $S_i = \sum_{j=0}^{N-1} \bar{D}_{ij}$, $i = 0, 1, \dots, N-1$

צעד 2: חפש את הסכום המקסימלי וסמן את השורה עם סכום זה ב- k . $S_k = \max_{i=0,1,\dots,N-1} S_i$

צעד 3: עבור כל שורה $i \neq k$

הוסף מטריצה במבנה צלב: $\bar{D} \leftarrow \bar{D} + \frac{1}{N}(S_k - S_i)(C_i + C_i^T)$

עדכן את סכום הסקלרים: $S \leftarrow S + \frac{1}{N}(S_k - S_i)$

צעד 4: חשב את הערכים העצמיים של מטריצת הערוץ Q , וסדר אותם בסדר

יורד $\lambda_0 \geq \lambda_1 \geq \dots \geq \lambda_{N-1}$. עבור הערוץ הבינארי הסימטרי היעור בנספח ב' (B.23).

הערה: $\lambda_0 = 1$ הוא הערך העצמי של Q המתאים לוקטור 1.

צעד 5: חשב את הערכים העצמיים של מטריצת המרחקים המשוקללת \bar{D}

וסדר אותם בסדר יורד $\omega_0 \geq \omega_1 \geq \dots \geq \omega_{N-1}$

הערה: ω_0 הוא הערך העצמי של \bar{D} המתאים לוקטור 1.

צעד 6: חשב את החסמים מתוך:

$$\frac{1}{2} \left(\lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \omega_{N-i} \right) - S \leq D_C \leq \frac{1}{2} \left(\lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \omega_i \right) - S$$

בסעיף הבא ניתנות דוגמאות ספציפיות למציאת החסמים.

6.3 זוגמאות מספריות

בסעיף זה נחשב את החסמים עבור מקרים ספציפיים. בגלל מספרם הרב ($N!$) של השיבוצים האפשריים, הגרלנו עבור כל מקרה 10,000 שיבוצים אקראיים וחישבנו את עיוות הערוץ בכל אחד מהם. נערוך השוואה בין החסמים לבין השיבוץ הטוב ביותר והשיבוץ הגרוע ביותר שנמצאו בסימולציה. ממוצע הסימולציה יצוין אף הוא.

עבור שני מקרים ערכנו השוואה בין החסמים לבין השיבוץ המתקבל מאלגוריתם החלפת זוגות המתואר ב-[Ze87]. בנוסף ערכנו במקרים אלו השוואה עם השיבוץ המתקבל באלגוריתם המתואר בפרק הבא.

6.3.1 קוונטיזר סקלרי אחיד ומקור אחיד תחת ערוץ בינארי סימטרי

בסוף נספח ג' תחת הערה מספר 3, מופיע חישוב מפורט של החסמים עבור קוונטיזר סקלרי אחיד, מקור אחיד וערוץ בינארי סימטרי. החסמים עבור מקרה זה חושבו גם בפרק 5. סכום הסקלרים

$$S = \frac{4(N-1)(N-2)}{3N^2} \quad \text{אשר הוספו למטריצה } \hat{D} \text{ לקבלת המטריצה } \tilde{D} \text{ הוא (C.18):}$$

הערכים העצמיים של המטריצה \tilde{D} הם (C.21):

$$\begin{aligned} \omega_0 &= \frac{4(N-1)^2}{N^2} \Leftrightarrow \underline{1} \\ \omega_1 &= \omega_2 = \dots = \omega_{N-2} = 0 \\ \omega_{N-1} &= -\frac{4(N-1)(N+1)}{3N^2} \end{aligned} \quad (6.12)$$

עבור הערוץ הבינארי הסימטרי הערכים העצמיים של המטריצה Q_N כפי שחושבו בנספח ב' הם:

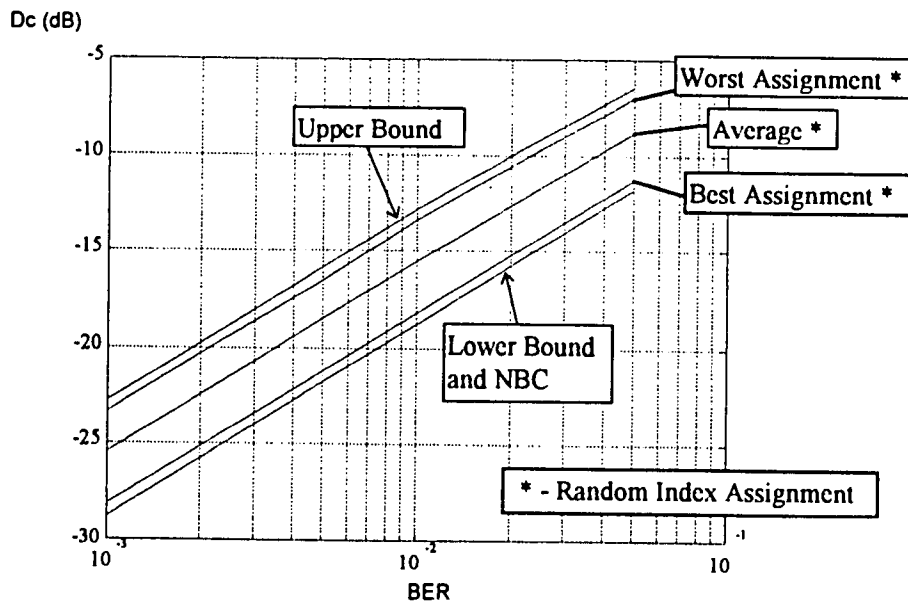
$$\begin{aligned} \lambda_0 &= 1 \Leftrightarrow \underline{1} \\ \lambda_1 &= 1-2q \\ &\vdots \\ \lambda_{N-1} &= (1-2q)^L \end{aligned} \quad (6.13)$$

הצבת הגדלים ב-(6.11) תיתן:

$$\frac{2(N+1)(N-1)}{3N^2} \cdot 2q \leq D_c \leq \frac{2(N+1)(N-1)}{3N^2} \left[1 - (1-2q)^L \right] \quad (6.14)$$

כפי שנתקבל ב-(5.13).

בציור 6.1 מופיעים החסמים עבור קוונטיזר בן 4 סיביות, בהשוואה לתוצאות הסימולציה. השיבוץ האופטימלי, שהוא הקוד הבינארי הסימטרי (NBC), מתלכד במקרה זה עם החסם התחתון.



ציור 6.1 - חסמים, עליון ותחתון, מעל כל שיבוצי הקוד האפשריים, על עיוות-הערוץ עבור קוונטיזר סקלרי אחיד בן 4 סיביות ומקור אחיד תחת ערוץ בינארי סימטרי. להשוואה מוצגות תוצאות סימולציה בה נבחנו 10,000 שיבוצים אקראיים. בציור סומנו השיבוץ הטוב ביותר שנמצא, השיבוץ הגרוע ביותר וממוצע הסימולציה. במקרה זה ביצועי הקוד הבינארי הטבעי (NBC) מזדהים עם החסם התחתון.

Fig 6.1 - Upper and lower bounds over all possible index assignments on the Channel-Distortion of a 4-bit Uniform Scalar Quantizer and a uniform source under the Binary Symmetric Channel.

Bounds are compared with the best and worst assignments of 10,000 randomly picked assignments. The lower bound coincides with the performance of the optimal assignment (Natural Binary Code)


ניתן להבחין כי החסמים במקרה זה רחוקים כ-0.5dB בלבד משיבוצים שנתקבלו בסימולציה. השיבוץ האופטימלי במקרה זה (NBC) לא התקבל בתהליך הסימולציה. לפי (5.14), המרחק בין החסמים עבור L סיביות הוא $10 \cdot \log_{10} L$ (dB), ועבור 4 סיביות כ-0.6dB. גם במקרה פשוט זה, ניתן לראות את החשיבות של שימוש מושכל בשיבוץ אינדקסים. הרווח עקב שיבוץ אינדקסים טוב צפוי לגדול עם העלייה במספר הסיביות.

6.3.2 קוונטייזר סקלרי אחיד ומקור אחיד תחת ערוץ בינארי סימטרי

עם קוד (7,4) Hamming לתיקון שגיאות

ניתן להשתמש בטכניקת החסימה שהוצגה בפרק זה גם עבור ערוצים חסרי זיכרון השונים מן הערוץ הבינארי הסימטרי. נסתכל כעת על ערוץ הכולל גם קוד בלוק לתיקון שגיאות. עבור קוונטייזר בעל 16 רמות ייצוג, ניתן לשבץ לכל רמה אינדקס ערוץ בן 7 סיביות תוך שימוש בטבלת Hamming Code (7,4). במקרה זה המרחק בין מלות קוד הוא לפחות 3 סיביות, ולכן הקוד מסוגל לתקן שגיאה בסיבית אחת.

עבור ערוץ זה, נסתכל על המקרה של קוונטייזר סקלרי אחיד ומקור אחיד מסעיף 6.3.1. עדיין עומדת לרשותנו המטריצה \tilde{D} והערכים העצמיים שלה. בציר 6.2 מופיעים החסמים עבור קוונטייזר בן 4 סיביות, בהשוואה לתוצאות הסימולציה.



ציר 6.2 - חסמים, עליון ותחתון, מעל כל שיבוצי הקוד האפשריים, על עיוות-הערוץ עבור קוונטייזר סקלרי אחיד בן 4 סיביות ומקור אחיד תחת ערוץ בינארי סימטרי וקוד Hamming (7,4). להשוואה מוצגות תוצאות סימולציה בה נבחנו 10,000 שיבוצים אקראיים. בציר סומנו השיבוץ הטוב ביותר שנמצא, השיבוץ הגרוע ביותר וממוצע הסימולציה. הקוד הבינארי הטבעי (NBC) מתלכד עם החסם התחתון.

Fig 6.2 - Upper and lower bounds over all possible index assignments on the Channel-Distortion of a 4-bit Uniform Scalar Quantizer and a uniform source under the Binary Symmetric Channel with (7,4) Hamming code. Bounds are compared with the best and worst assignments of 10,000 randomly picked assignments. The Natural Binary Code coincide with the lower bound.

מהסתכלות בתוצאות הנומטריות עולה כי במקרה זה החסם העליון רחוק כ-0.6dB מן השיבוץ הגרוע ביותר שנתקבל בסימולציה. החסם התחתון רחוק רק ב-0.1dB מן השיבוץ הטוב ביותר שנתקבל. המרחק בין החסמים עומד על 4.5dB בערך. ניתן לראות כי השימוש בקוד לתיקון שגיאות הוריד את ההפרש בביצועים בין שיבוץ "טוב" לבין שיבוץ "גרוע".

מעניין לציין כי בדומה לערוץ הבינארי הסימטרי, מטריצת הערוץ Q ניתנת ללכסון ע"י מטריצת Walsh-Hadamard. הוכחה מפורטת של עובדה זו מופיעה בנספח ד'. וקטור רמות הייצוג ρ (5.1) הוא וקטור עצמי המתאים לערך העצמי הגדול ביותר, פרט ל-1. מסיבה זו הקוד הבינארי הטבעי (NBC) מתלכד עם החסם התחתון.


המסקנה היא שגם עבור ערוץ זה הקוד הבינארי הסימטרי הוא השיבוץ האופטימלי.

6.3.3 קוונטיזר אחיד מותאם למקור גאוסי תחת ערוץ בינארי סימטרי

נתייחס לקוונטיזר אחיד בן 4 סיביות שצעד הקוונטיזציה שלו מותאם לפילוג גאוסי [Ja84] סעיף 4.3.2. מטריצת הערוץ זהה לזו שבסעיף 6.3.1. למציאת החסם חישבנו את מטריצת המרחקים המשוקללת ואת הערכים העצמיים שלה:

$$\begin{aligned} \omega_0 &\approx 9.427 & ; & \omega_3 \approx \dots \approx \omega_{13} \approx 0 \\ \omega_1 &\approx 1.248 & ; & \omega_{14} \approx -3.281 \\ \omega_2 &\approx 0.372 & ; & \omega_{15} \approx -4.131 \end{aligned} \quad (6.15)$$

בציור 6.3 מופיעים החסמים עבור קוונטיזר בן 4 סיביות, בהשוואה לתוצאות הסימולציה. בנוסף מופיעים בציור הביצועים עבור שיבוץ המתקבל מאלגוריתם החלפת זוגות המתואר ב-[Ze87]. בנוסף ערכנו השוואה עם השיבוץ המתקבל באלגוריתם לשיבוץ אינדקסים המתואר בפרק 7.



ציור 6.3 - חסמים, עליון ותחתון, מעל כל שיבוצי הקוד האפשריים, על עיוות-הערוץ עבור קוונטיזר סקלרי אחיד בן 4 סיביות מותאם לפילוג גאוזי תחת ערוץ בינארי סימטרי. להשוואה מוצגות תוצאות סימולציה בה נבחנו 10,000 שיבוצים אקראיים. בציור סומנו השיבוץ הטוב ביותר שנמצא, השיבוץ הגרוע ביותר וממוצע הסימולציה. בנוסף הובאו בציור הביצועים של השיבוצים המתקבלים מאלגוריתם החלפת אינדקסים המתואר ב-[Ze87] ואלגוריתם המוצע בפרק 7.

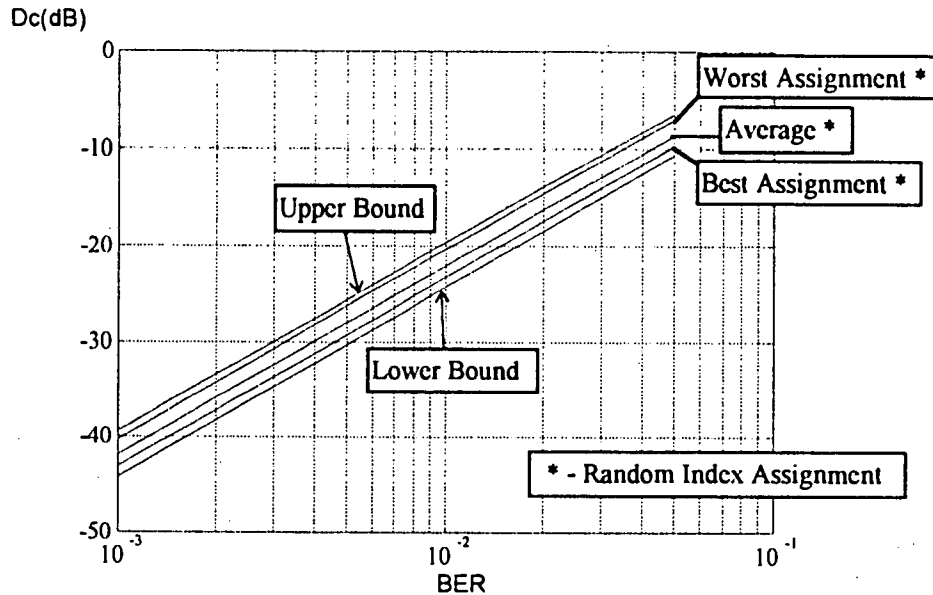
F 6.3 - Upper and lower bounds over all possible index assignments on the Channel-Distortion of a 4-bit PDF optimized Uniform Scalar Quantizer and a Gaussian source under the Binary Symmetric Channel. Bounds are compared with the best and worst assignments of 10,000 randomly picked assignments. Bounds are also compared with the performance of Index Assignments obtained from Index switching algorithm [Ze87] and the algorithm proposed in Chapter 7.

מהסתכלות בתוצאות הנומריות עולה כי במקרה זה החסם העליון רחוק כ-0.6dB מן השיבוץ הגרוע ביותר שנתקבל בסימולציה. החסם התחתון רחוק ב-6dB מן השיבוץ הטוב ביותר שנתקבל בסימולציה. המרחק בין החסמים עומד על 12dB בערך. ניתן לראות כי חיפוש אקראי של שיבוצים (10^4 שיבוצים מתוך $2 \cdot 10^{13}$ שיבוצים אפשריים) לא נתן מידע מספיק על הביצועים שניתן להשיג מן המערכת עבור שיבוצים שונים. השיבוץ שנתקבל באלגוריתם חילופי הזוגות הביא לשיבוץ טוב מזה שנמצא בחיפוש האקראי. השיבוץ שנתקבל מן האלגוריתם המתואר בפרק 7. נתן שיבוץ טוב עוד יותר.

6.3.4 קוונטייזר אחיד מותאם למקור גאוסי תחת ערוץ בינארי סימטרי

עם קוד Hamming (7,4) לתיקון שגיאות

נתבונן בקוונטייזר מסעיף 6.3.3. עומדת לרשותנו מטריצת המרחקים המשוקללת מן הסעיף הקודם. בציר 6.4 מופיעים החסמים עבור קוונטייזר בן 4 סיביות, בהשוואה לתוצאות הסימולציה.



ציור 6.4 - חסמים, עליון ותחתון, מעל כל שיבוצי הקוד האפשריים, על עיוות-הערוץ עבור קוונטייזר סקלרי אחיד בן 4 סיביות מותאם לפילוג גאוסי תחת ערוץ בינארי סימטרי וקוד Hamming (7,4).

להשוואה מוצגות תוצאות סימולציה בה נבחנו 10,000 שיבוצים אקראיים.


בציור סומנו השיבוץ הטוב ביותר שנמצא, השיבוץ הגרוע ביותר וממוצע הסימולציה.

F 6.4 - Upper and lower bounds over all possible index assignments on the Channel-Distortion of a 4-bit PDF optimized Uniform Scalar Quantizer and a Gaussian source under the Binary Symmetric Channel with (7,4) Hamming code. Bounds are compared with the best and worst assignments of 10,000 randomly picked assignments.

מהסתכלות בתוצאות הנומריות עולה כי במקרה זה החסם העליון רחוק כ-0.9dB מן השיבוץ הגרוע ביותר שנתקבל בסימולציה. החסם התחתון רחוק ב-0.8dB מן השיבוץ הטוב ביותר שנתקבל. המרחק בין החסמים עומד על 3dB בערך. בדומה למקור האחד גם כאן תוספת הקוד לתיקון שגיאות הורידה את ההפרש בין שיבוץ "טוב" לשיבוץ "גרוע".

6.3.5 קוונטייזר וקטורי מותאם למקור גאוסי תחת ערוץ בינארי סימטרי

לצורך סעיף זה השתמשנו בקוונטייזר וקטורי בן 8 סיביות, 2 סיביות לדגימה שתוכנן עבור מקור גאוס-מרקוב עם מקדם מתאם 0.5 (ראה גם ציור 3.3). בציור 6.5 מופיעים החסמים עבור הקוונטייזר, בהשוואה לתוצאות הסימולציה. הפעם נעשתה השוואה מול 100,000 שיבוצים אקראיים. בנוסף מופיעים בציור הביצועים עבור שיבוץ המתקבל מאלגוריתם החלפת זוגות המתואר ב-[Ze87]. בנוסף ערכנו השוואה עם השיבוץ המתקבל באלגוריתם לשיבוץ אינדקסים המתואר בפרק 7.



ציור 6.5 - חסמים עליון ותחתון מעל כל שיבוצי הקוד האפשריים על עיוות-הערוץ עבור קוונטייזר וקטורי בן 8 סיביות (2 סיביות לדגימה) מותאם לפילוג גאוסי (מקדם מתאם 0.5) תחת ערוץ בינארי סימטרי. להשוואה מוצגות תוצאות סימולציה בה נבחנו 100,000 שיבוצים אקראיים. בציור סומנו השיבוץ הטוב ביותר שנמצא, השיבוץ הגרוע ביותר וממוצע הסימולציה. בנוסף הובאו בציור הביצועים של השיבוצים המתקבלים מאלגוריתם החלפת אינדקסים המתואר ב-[Ze87] ואלגוריתם המוצע בפרק 7.

Fig 6.5 - Upper and lower bounds over all possible index assignments on the Channel-Distortion of a 8-bit Vector Quantizer (2 bit/sample) and a Gaussian source (correlation 0.5) under the Binary Symmetric Channel.

Bounds are compared with the best and worst assignments of 100,000 randomly picked assignments. Bounds are also compared with the performance of Index Assignments obtained from Index switching algorithm [Ze87] and the algorithm proposed in Chapter 7.

ניתן לראות כי החסם העליון רחוק כ-2dB מן השיבוץ הגרוע ביותר שנמצא. החסם התחתון רחוק כ-3dB מהשיבוץ הטוב ביותר שנמצא בחיפוש. המרחק בין החסמים הוא כ-11dB. ההפרש בין השיבוץ הגרוע ביותר לשיבוץ הטוב ביותר הוא כ-6dB. תוצאה נומרית דומה מופיע ב-[Ze90]. גם בדוגמה זו ניתן לראות כי חיפוש אקראי של שיבוצים איננו מספק מבחינת מציאת שיבוץ אינדקסים יעיל. השיבוץ שנתקבל באלגוריתם חילופי הזוגות הביא לשיבוץ טוב מזה שנמצא בחיפוש האקראי. השיבוץ שנתקבל מן האלגוריתם המתואר בפרק 7. נתן שיבוץ טוב עוד יותר.

6.4 סיכום

בפרק זה הוצגו חסמים על עיוות הערוץ מעל כל השיבוצים האפשריים של מילות קוד לוקטורים מייצגים. החסמים יכולים להיות מיושמים על קוונטיזרים סקלריים ווקטוריים כלשהם. אין הגבלה גם על מידת המרחק ועל הסתברויות המקורות. הדרישה על הערוץ היא היותו חסר-זיכרון וסימטרי. כמו-כן הוצגו חסמים מספריים עבור מקרים ספציפיים.

החסמים הינם הרחבה של התוצאות מפרק 5, שם נמצאו חסמים עבור המקרה המיוחד של קוונטיזר סקלרי אחיד, מקור אחיד וערוץ בינארי סימטרי ונמצא כי השיבוץ הבינארי הטבעי (NBC) הוא השיבוץ האופטימלי. בפרק זה הוכחנו כי הקוד הבינארי הטבעי הוא השיבוץ האופטימלי עבור מקרה נוסף: קוונטיזר סקלרי אחיד, מקור אחיד וערוץ בינארי סימטרי עם קוד Hamming (7,4) לתיקון שגיאות.

השוואה נוספת נעשתה עם 10,000 קודים שנבחרו באקראי (כאשר עבור קוונטיזר וקטורי עם 8 סיביות נעשתה השוואה עם 100,000 קודים).

כאשר השוונו ביצועים של קוונטיזר הפועל תחת הערוץ הבינארי הסימטרי, ראינו בדוגמאות המספריות כי תוספת הקוד לתיקון שגיאות הורידה את ההפרש בין הביצועים של שיבוצים טובים לשיבוצים גרועים.

השוונו את החסמים לביצועים עם שיבוץ המתקבל מאלגוריתם של חילופי זוגות וכן עם השיבוץ לפי האלגוריתם המוצע בפרק 7. במקרים שנבדקו נתן השיבוץ שהתקבל מן האלגוריתם הראשון ביצועים טובים מחיפוש אקראי בעוד שהאלגוריתם המתואר בפרק 7 נתן ביצועים טובים עוד יותר.

פרק 7 - אלגוריתם תת-אופטימלי למציאת שיבוץ אינדקסים עבור ערוץ סימטרי חסר זיכרון

7.1 מבוא

בפרקים הקודמים עמדנו על מספרם העצום של השיבוצים האפשריים של מילות קוד לוקטורי-ייצוג בקוונטיזורים וקטוריים. ראינו בפרק 5 כי במקרה המיוחד של קוונטיזור סקלרי אחד, מקור אחד וערוץ בינארי סימטרי, ניתן להצביע על השיבוץ האופטימלי, שהוא הקוד הבינארי הטבעי. בפרק 6 תוארו חסמים על עיוות הערוץ מעל כל $M!$ השיבוצים האפשריים של מילות קוד בקוונטיזורים וקטוריים כלשהם. החסמים ניתנים ליישום עבור ערוצים חסרי-זיכרון סימטריים. בפרק זה נתאר אלגוריתם קונסטרוקטיבי תת-אופטימלי למציאת שיבוץ אינדקסים עבור קוונטיזור וקטוריים הפועלים תחת ערוץ סימטרי חסר זיכרון. פיתוח האלגוריתם מופיע בשלמותו בנספח ה', בפרק זה נציג את תקציר הפיתוח בלבד. האלגוריתם מבוסס על תוצאות שנתנו בפרק 6. הסיבוכיות של האלגוריתם היא $O(N^3)$. בדוגמאות מספריות שהוצגו בפרק 6, השוונו את ביצועי האלגוריתם המוצע עם ביצועי אלגוריתם חילופי-אינדקסים, בעל סיבוכיות $O(N^4)$. ראינו כי ביצועי האלגוריתם המוצע טובים מביצועי האלגוריתם של חילופי-אינדקסים.

7.2 תקציר פיתוח האלגוריתם

לפי (2.15), ביטוי כללי לעיוות הערוץ ניתן ע"י:

$$D_c = \text{trace}\{P\pi Q_N \pi^T D\} \quad (7.1)$$

אנו מניחים כי מטריצת הערוץ Q_N הינה סימטרית. מכיוון שהיא מייצגת הסתברויות, סכום כל שורה שווה לאחד ולכן $Q_N \cdot \mathbf{1} = \mathbf{1}$. אין הנחות נוספות על מטריצת ההסתברויות P (אלכסונית) ועל מטריצת המרחקים בין הווקטורים המיצגים D . השיבוץ מתואר ע"י מטריצת הפרמוטציה π .

בפרק 6 ראינו כי בעיית מציאת המינימום לעיוות הערוץ שקולה לפתרון הבעיה:

$$\min_{\pi} \text{trace}\{Q_N \pi^T \bar{D} \pi\} \quad (7.2)$$

כאשר מטריצת המרחקים המשוקללת \bar{D} נתקבלה מן המטריצות P ו- D ע"י אלגוריתם המתואר בסעיף 6.2.2 ובנספח ג'. המטריצה \bar{D} היא סימטרית ומקיימת את התכונה כי הוקטור $\underline{1}$ הוא וקטור עצמי שלה עם ערך עצמי מתאים ω_0 .

נבצע לכסון יוניטרי למטריצת הערוץ הסימטרית Q_N ולמטריצת המרחקים המשוקללת \bar{D} .

$$\begin{aligned} Q_N &= V \cdot \Lambda \cdot V^T & V \cdot V^T &= I \\ \bar{D} &= Z \cdot \Omega \cdot Z^T & Z \cdot Z^T &= I \end{aligned} \quad (7.3)$$

נסדר את הערכים העצמיים של המטריצות בסדר יורד. כאשר הערך העצמי הראשון של Q_N הוא $\lambda_0 = 1$ והוקטור העצמי המתאים הוא $\frac{1}{\sqrt{N}} \cdot \underline{1}$. באופן דומה, הערך העצמי הראשון של \bar{D} הוא ω_0 והוקטור העצמי המתאים הוא $\frac{1}{\sqrt{N}} \cdot \underline{1}$. ראינו בסעיף 6.2.4 כי עבור מטריצות סימטריות אי-שליליות בעלות וקטור עצמי השווה ל- $\underline{1}$, הערך העצמי המתאים הוא הערך העצמי הגדול ביותר בערך מוחלט (לפי Perron-Frobenius [La85], סעיף 15.3). נציב את (7.3) ב-(7.2):

$$\begin{aligned} \min_{\pi} \text{trace}\{V \cdot \Lambda \cdot V^T \pi^T Z \cdot \Omega \cdot Z^T \pi\} &= \\ \min_{\pi} \text{trace}\{\Lambda \cdot V^T \pi^T Z \cdot \Omega \cdot Z^T \pi \cdot V\} &= \\ \Leftrightarrow \text{trace}\{AB\} &= \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} A_{ij}^T B_{ij} \\ \min_{\pi} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \lambda_j \omega_i (Z^T \pi V)_{ij}^2 &= \\ \min_{\pi} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \lambda_j \omega_i \Psi_{ij}^2 & \end{aligned} \quad (7.4)$$

המטריצה $\Psi = Z^T \pi V$ היא יוניטרית מכיוון ש:

$$\Psi \Psi^T = (Z^T \pi V)(Z^T \pi V)^T = Z^T \pi V V^T \pi^T Z = Z^T \pi \pi^T Z = Z^T Z = I \quad (7.5)$$

מכיוון שהעמודה הראשונה של V והעמודה הראשונה של Z הן $\underline{z}_0 = \underline{v}_0 = \frac{1}{\sqrt{N}} \underline{1}$, ושאר העמודות אורתוגונליות לוקטור $\underline{1}$, הרי שלמטריצה Ψ יש את המבנה הבא:

$$\Psi = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & & & \\ \vdots & & ? & \\ 0 & & & \end{bmatrix}$$

(7.6)

כאשר סימן השאלה מתאר איברים לא ידועים.

בנספח ג' (C.12) ראינו כי אם המטריצה היוניטרית πV מוחלפת במטריצה יוניטרית כללית, U , אזי הערך המינימלי של פונקצית המטרה ב-(7.4) מתקבל עבור:

$$\Psi^* = \begin{bmatrix} 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & & & 1 \\ \vdots & & & & 1 \\ 0 & & \dots & & \\ 0 & 1 & & & 0 \end{bmatrix}$$

(7.7)

המטריצה Ψ^* איננה תוצאה של מטריצת פרמוטציה חוקית בביטוי $\Psi = Z^T \pi V$, ולכן נבצע קירוב של π ע"י מטריצה יוניטרית כללית. אם נחליף את מטריצת הפרמוטציה π במטריצה יוניטרית כללית W , הערך המינימלי של פונקצית המטרה יתקבל עבור $W = Z\Psi^*V^T$. יש לשים לב כי מכיוון ש- W יוניטרית, כל איברי המטריצה קטנים בערכם המוחלט מ-1,

$$|W_{ij}| \leq 1, \quad i, j = 0, 1, \dots, N-1$$

נחפש כעת מטריצת פרמוטציה "קרובה" למטריצה W , ע"י פתרון בעיית שיבוץ רגילה הידועה מתורת חקר ביצועים.

$$\begin{aligned} \min_{\pi} \quad & \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (1 - w_{ij}^2) \pi_{ij} \\ \text{s.t.} \quad & \sum_{j=0}^{N-1} \pi_{ij} = 1 \quad i = 0, 1, \dots, N-1 \\ & \sum_{i=0}^{N-1} \pi_{ij} = 1 \quad j = 0, 1, \dots, N-1 \\ & \pi_{ij} \geq 0 \end{aligned} \tag{7.8}$$

פונקצית המשקל $(1 - w_{ij}^2)$ הנה אחת מפונקציות משקל אפשריות, אשר נבחרה כי היא נמצאה יעילה בפתרון המקרים הספציפיים אותם בדקנו.

פתרון בעיית השיבוץ (7.8), יכול להיעשות בשיטה ההוגרית [Ta87 סעיף 6.3].
 התוצאה של האלגוריתם היא מטריצת פרמוטציה π , בה ניתן להשתמש בבעיה המקורית (7.1).

האלגוריתם מורכב מן השלבים הבאים:

1. מציאת ערכים עצמיים של שתי מטריצות הרמיטיות [Go89 סעיף 8.2]: $O(N^3)$.

2. כפל מטריצות: $O(N^2)$.

3. פתרון בעיית שיבוץ סטנדרטית [Ta87 סעיף 6.3]: $O(N^3)$.

סה"כ הסיבוכיות של האלגוריתם היא $O(N^3)$.

7.3 שימוש באלגוריתם למקרים אסימפטוטיים

בסעיף 3.4 דנו בערוץ הבינארי הסימטרי ובערוצים הנובעים ממנו ע"י קוד בלוק לתיקון שגיאות, כדוגמת קוד Hamming. איברי מטריצת הערוץ Q תלויים בהסתברות השגיאה בערוץ הבינארי הסימטרי q . נסמן עובדה זו באופן מפורש ע"י $Q(q)$. מכיוון שאיברי האלכסון במטריצת הערוץ מתארים קליטה ללא שגיאה, הגדרנו ב-(3.4) מטריצה בעלת אלכסון המכיל אפסים:

$$\bar{Q}_{ij}(q) = \begin{cases} Q_{ij}(q) & i \neq j \\ 0 & i = j \end{cases} \quad (7.9)$$

חיפשנו את גורם השגיאה הדומיננטי בשאר איברי מטריצת הערוץ. המטריצה $\bar{Q}(q)$ מורכבת מסכומים של איברים מן הצורה $q^l(1-q)^{L-l}$, $l = L^0, L^0 + 1, \dots, L$, כאשר סימנו את החזקה הנמוכה ביותר ב- L^0 . הסיבה לכך שאיפסנו את האלכסון של המטריצה המקורית $Q(q)$ היא שהיו באלכסון איברים בחזקות נמוכות יותר מ- L^0 . נבחן את הגבול:

$$\lim_{q \rightarrow 0} \frac{1}{q^{L^0}} \cdot \bar{Q}(q) = \bar{Q}_A \quad (7.10)$$

איברים עם חזקות של q הגבוהות מ- L^0 יתאפסו בגבול. קצב השגיאות בערוץ איננו מופיע לכן במטריצה \bar{Q}_A . שימוש במטריצה \bar{Q}_A בבעיה המקורית (7.1) יביא לשיבוץ המתאים לתחום של קצבי שגיאה בערוץ מאפס שגיאות (ואז השיבוץ איננו חשוב) ועד לקצב q_0 בו הקירוב האסימפטוטי איננו מתאים. ראינו בפרק 3 כי ההתנהגות האסימפטוטית של עיוות הערוץ קרובה מאד להתנהגות האמיתית מהסתברויות שגיאה בערוץ של 5% – 1 ומטה.

7.4 סיכום

בפרק זה הוצג אלגוריתם תת-אופטימלי למציאת שיבוץ של אינדקסים לוקטורי ייצוג בקוונטיזרים וקטוריים הפועלים תחת ערוץ סימטרי חסר זיכרון. הראינו כי לאלגוריתם סיבוכיות $O(N^3)$ בהשוואה לסיבוכיות $O(N^4)$ של אלגוריתם חילופי-אינדקסים המתואר בספרות. הצגנו גם את הגישה לשיבוץ עבור המקרה האסימפטוטי של קצבי שגיאה נמוכים בערוץ. עבור קצבי שגיאה נמוכים ($q_0 \approx 1-5\%$ ומטה) מתקבל שיבוץ טוב לכל התחום מאפס שגיאות (ואז השיבוץ איננו חשוב) ועד לקצב q_0 .

השיבוץ שנתקבל עבור מקרים ספציפיים תואר בפרק 6, שם הראינו כי חיפוש אקראי של מספר מוגבל של שיבוצים רחוק מן השיבוץ שהוצג כאן. בנוסף השווינו בשני מקרים את הביצועים המתקבלים מאלגוריתם של חילופי-אינדקסים לביצועי האלגוריתם המוצע. האלגוריתם המוצע נמצא עדיף בשני המקרים.

פרק 8 - סיכום, מסקנות והצעות להמשך מחקר

8.1 סיכום

עבודת מחקר זו עוסקת בחקר הביצועים של מערכות קידוד המבוססות על קוונטיזציה וקטורית, כאשר המידע הספרתי מועבר דרך ערוצי תקשורת רועשים ובדרכים לשיפור הביצועים של מערכות אלו.

בהצגת הבעיה ראינו כי ניתן להתייחס אל העיוות הכולל כמורכב מעיוות קוונטיזציה הנגרם מייצוג האות האנלוגי (או אות דגום ברזולוציה אמפליטודה גבוהה) ע"י מידע ספרתי ומעיוות ערוץ הנגרם כתוצאה משגיאות במידע הספרתי שהועבר בערוץ. בעבודה עסקנו אך ורק בערוצים חסרי זיכרון.

בחלקה הראשון העבודה מפותחים חסמים על עיוות הערוץ מעל כל מקורות האות האפשריים במערכות נתונות. חסמים אלו מספקים למתכנן מידע כמותי על עיוות הערוץ. פיתוח החסמים מבוסס על תכונות הידועות מתורת התכנות הליניארי. הוצגו מספר דוגמאות מספריות להדגמת החסמים. ראינו כי עבור המקרה המיוחד של קוונטיזציה סקלרי אחיד, שיבוץ אינדקסים בקוד בינארי טבעי וערוץ בינארי סימטרי התלכדו החסמים בהסתברויות שגיאיה בערוץ, q , של עד 5%. בדוגמאות אחרות, המרווח בין החסם העליון לחסם התחתון הוא גדול יחסית וידיעתם איננה תורמת מספיק להערכת ביצועי המערכת. עבור מקרים אלו מוצגים חסמים הדוקים יותר עבור משפחה מצומצמת יותר של מקורות, המאופיינת ע"י מומנטים של הסתברות המקור ובפרט אילוץ על הספק המקור. כמו-כן מוצגים חסמים אסימפטוטיים עבור ערוץ בינארי סימטרי (בלי או עם קוד לתיקון שגיאות) כאשר הסתברות השגיאה בערוץ שואפת לאפס, $q \rightarrow 0$. ההתנהגות האסימפטוטית של עיוות הערוץ מאופיינת בשיפוע התלוי באופי הערוץ. למשל, עבור ערוץ בינארי סימטרי, הראינו כי ללא קוד לתיקון שגיאות עיוות הערוץ תלוי ביחס ישר להסתברות השגיאה בערוץ q , ואילו עבור קוד המתקן שגיאה בסיבית אחת, עיוות הערוץ תלוי ביחס ישר ל- q^2 . הראינו גם שעבור קוונטיזציה סקלרי אחיד בן L סיביות, גודלו של עיוות הערוץ כמעט ואינו תלוי ב- L , כאשר משתמשים בשיבוץ הבינארי הטבעי. יתירה מזו, עבור $L \geq 4$, עיוות הערוץ עבור השיבוץ הבינארי הטבעי קטן יותר ממוצע העיוות מעל כל השיבוצים האפשריים, עבור כל מקור שהוא.

בנוסף למציאת חסמים על ביצועי מערכות קוונטיזציה וקטורית נתונות, העבודה מתרכזת בשני גורמים המשפיעים על עיוות הערוץ. הגורם הראשון הוא מבנה הקוונטיזציה (הסקלרי כמקרה פרטי) מבחינת תאי חלוקה ווקטורי ייצוג. הגורם השני הוא שיבוץ האינדקסים המשודרים בערוץ לוקטורי הייצוג.

קוונטיזציה וקטורית המתוכנן ללא התחשבות בשגיאות ערוץ מבוסס בדרך כלל על שני תנאים הכרחיים לאופטימליות: תנאי השכן הקרוב ותנאי הצנטרואיד. כאשר מתחשבים בשגיאות ערוץ, הוצגו בספרות תנאים הכרחיים אלטרנטיביים: תנאי השכן הקרוב המשוקלל ותנאי הצנטרואיד המשוקלל. תנאים אלו מביאים לתכן מסובך של הקוונטיזציה ולמימוש יקר מבחינת דרישות זיכרון. בעבודה מוצגת גישה תת-אופטימלית המשתמשת בקוונטיזציה שתוכנן ללא התחשבות

בשגיאות הערוץ, תוך ביצוע כיווץ ליניארי של תאי החלוקה ווקטורי הייצוג. הגישה שהוצגה היא פשוטה לתכנון וזולה למימוש, תוך תשלום לא גדול בביצועים בהשוואה לאלגוריתמים האופטימליים.

ראינו כי עיוות הערוץ מושפע משיבוץ מילות הקוד לוקטורי הייצוג של הקוונטיזר. מספרם הרב של השיבוצים האפשריים ($N!$ עבור קוונטיזר בעל N וקטורי ייצוג) איננו מאפשר בדרך כלל חיפוש ממצה ע"י בדיקה של כולם. בעבודה פותחו חסמים על עיוות הערוץ מעל כל השיבוצים האפשריים של אינדקסים לוקטורי ייצוג עבור ערוץ חסר זיכרון. חסמים אלו מאפשרים למתכנן להעריך את השפעת השיבוץ על המערכת שבתכנון.

עבור המקרה המיוחד של קוונטיזר סקלרי אחיד ומקור אחיד הפועל בערוץ בינארי סימטרי ניתנת הוכחה כי הקוד הבינארי הטבעי הוא השיבוץ האופטימלי.

בנוסף, עבור ערוצים סימטריים חסרי זיכרון, קוונטיזר ומקור כלשהם, מפותח בעבודה אלגוריתם תת-אופטימלי למציאת שיבוץ יעיל של מילות קוד לוקטורי הייצוג בקוונטיזר. סיבוכיות האלגוריתם היא $O(N^3)$. בהשוואות מספריות נותן האלגוריתם שיבוץ בעל ביצועים עדיפים על השיבוץ המתקבל מאלגוריתם של חילופי אינדקסים המוצג בספרות, על אף שסיבוכיותו גבוהה יותר $O(N^4)$.

בעזרת סימולציות מחשב, נעשתה השוואה בין החסמים על עיוות הערוץ מעל כל השיבוצים האפשריים, חיפוש בעשרת אלפים (מאה אלף באחד המקרים) שיבוצים אקראיים ועבור שני מקרים גם עם השיבוץ התת-אופטימלי המוצע. מן ההשוואות עולה כי החיפוש האקראי איננו מביא לתוצאות מספקות בגלל העושר הרב של שיבוצים אפשריים (עבור קוונטיזר של 4 סיביות בלבד קיימים $2 \cdot 10^{13}$ שיבוצים אפשריים). עבור המקרה המיוחד של קוונטיזר סקלרי אחיד ושיבוץ בינארי טבעי, מתלכד השיבוץ המוצע עם החסם התחתון. במקרה טיפוסי שנבדק בסימולציה, נמוך עיוות הערוץ עבור השיבוץ האופטימלי ב-8dB בהשוואה לממוצע של עיוות הערוץ מעל כל השיבוצים האפשריים. עבור אותו מקרה ביצועי אלגוריתם חילופי האינדקסים גרועים ב-1dB מן האלגוריתם המוצע.

8.2 הצעות להמשך מחקר

- בעבודה זו התמקדנו בשגיאות ערוץ עבור ערוצים חסרי זיכרון. הרחבתן של התוצאות ובעיקר נושאי השיבוץ לערוצים בעלי זיכרון הינה בעלת חשיבות למערכות מעשיות.
- הרחבה של הגישה התת-אופטימלית של שינוי ליניארי במבנה הקוונטיזר להקטנת השפעתן של שגיאות ערוץ ע"י שימוש בפונקציה כיווץ לא ליניארית. חסרונה העיקרי של שיטת הכיווץ הליניארי היא בהגדלת רעש ההעמסה (Overload Noise) עבור כיווץ משמעותי של הקוונטיזר. עיוות לא ליניארי אשר יבצע כיווץ חזק יחסית במרכז לעומת קצות התחום, יתכן ויביא לביצועים

טובים יותר. יתרונה של גישה זו הוא שגם עם פונקצית כיווץ מסובכת יותר, התכן עדיין מבוסס על קוונטיזציה שתוכנן ללא התחשבות בשגיאות ערוץ ואין צורך לתכנן ולשמור ספריית קוונטיזציה. גישה אפשרית נוספת היא, שאם איבר אחד בוקטורים המיועדים לקידוד מציג התנהגות שונה מן היתר, ייתכן וכדאי למצוא לו פונקצית כיווץ אינדבידואלית. במקרה זה נקבל בעייה בשני משתני כיווץ $\min_{\alpha_1, \alpha_2} D(\alpha_1, \alpha_2)$ ויש לחפש מינימום בפונקציה הדו-מימדית. ניתן, כמובן, לבצע הרחבה ליותר משני מימדים.

• הרחבה של בעיית שיבוץ האינדקסים גם למערכות קידוד מקור-ערוץ משולבות. לדוגמה, עבור קוונטיזציה וקטורי בן $N = 2^L$ וקטורי ייצוג, ניתן להשתמש בערוץ עם אלפבית בגודל $M = 2^L > N$. הסיביות הפנויות יכולות לשמש לתיקון שגיאות. בעיית השיבוץ כעת היא בסיבוכיות גבוהה עוד יותר. יש להחליט לאילו וקטורי ייצוג ישובצו אילו אינדקסים (כאשר יישארו $M - N$ אינדקסים פנויים), ואילו וקטורים מייצגים יפוענחו במקלט לכל אינדקס ערוץ שנקלט. ראוי לציין כי במאמר שתואר בסקר הספרות [Fa87] ההתייחסות לשיבוץ שונה מן הגישה שלנו.

• בדיקת האופטימליות של הקוד הבינארי הטבעי עבור קודים אחרים לתיקון שגיאות (מלבד הקוד הספציפי שנבדק (Hamming (7,4)).

References

מקורות ספרות

- [Be92] Ben-David G. and Malah D., "On the Performance of a Vector-Quantizer under Channel Errors", *Signal Processing VI Theories and applications, Proceeding of EUSIPCO-92*, Elsevier Amsterdam, pp. 1685-1688, Aug. 1992.
- [Be93] Ben-David G. and Malah D., "Properties of the Natural Binary Code Assignment for Uniform Scalar Quantizers under Channel Errors", *Proc. of the ECCTD-93*, Elsevier Amsterdam, pp. 773-778, Sep. 1993.
- [Be93] Ben-David G. and Malah D., "Simple Adaptation of Vector-Quantizers to Combat Channel Errors", *Proc. of the IEEE DSP-94 Workshop*, IEEE, Piscataway NJ, pp. 41-44, Oct. 1994.
- [Bu79] Burkard E., "Travelling Salesman and Assignment Problems: A Survey", *Annal of Discrete Mathematics 4*, North-Holland publishing - Amsterdam, pp. 193-215, 1979.
- [Ch87] Chen J.H., Davidson G., Gersho A. and Zeger K., "Speech Coding for the Mobile Satellite Experiment", *Proc. IEEE Int. Conf. on Communication*, Seattle, WA pp. 756-763, June 1987.
- [Ch93] Chaing D.M. and Potter L., "Minimax Non-redundant Channel-Coding for Vector Quantization", *Proc. ICASSP-93*, Minneapolis, Minnesota, pp. 617-620, April 1993.
- [Cl85] Clarke R.J., *Transform Coding of Images*, Academic-Press London, 1985.
- [Cr69] Crimmins T.R., Horwitz H.M, Palermo C.J and Palermo R.V., "Minimization of Mean-Square Error for Data Transmitted Via Group Codes", *IEEE Trans. Inform. Theory*, vol. 15, no. 1, pp. 72-78, Jan. 1969.
- [Cu94] Cuperman V., Liu F.H. and Ho P., "Robust Vector Quantization for Noisy Channels Using Soft Decision and Sequential Decoding", *European Tran. Telecommunication*, vol. 5, no. 5, pp.7/541-18/552, Oct. 1994.
- [De87] De Marca J.R.B and Jayant N.S., "An algorithm for Assigning Binary Indices to the Codevectors of Multi-Dimensional Quantizer", *Proc. IEEE Intl. Conf. Comm.*, Seattle, WA, pp. 1128-1132, June 1987.
- [Fa87] Farvardin N. and Vaishampayan V., "Optimal Quantizer Design for Noisy Channels: An Approach to Combined Source-Channel Coding", *IEEE Trans. Inform. Theory*, vol. 33, no. 6, pp. 827-838, Nov. 1987.
- [Fa90] Farvardin N., "A Study of Vector Quantization for Noisy Channels", *IEEE Trans. Inform. Theory*, vol. 36, no. 4, pp. 799-809, July 1990.

- [Fa91] Farvardin N. and Vaishampayan V., "On the Performance and Complexity of Channel-Optimized Vector Quantizers", *IEEE Trans. Inform. Theory*, vol. 37, no. 1, pp. 155-159, Jan. 1991.
- [Fl64] Fleischer P.E., "Sufficient Conditions for Achieving Minimum Distortion in a Quantizer", *1964 IEEE Intl. Conv. Rec.*, pp. 104-111.
- [Ge92] Gersho A. and Gray R.M., *Vector Quantization and Signal Compression*, Kluwer Academic Publishers, Boston, 1992.
- [Gi62] Gilmore P.C., "Optimal and Suboptimal Algorithms for the Quadratic Assignment Problem", *J. Soc. Indust. Appl. Math.*, vol. 10, no.2, pp. 305-313, June 1962.
- [Go89] Golub G.H. and Van-Loan C.F, *Matrix Computations*, The John Hopkins University Press, Baltimore, 1989.
- [Ha70] Hall K.M., "An r-Dimensional Quadratic Placement Algorithm", *Management Science*, The Institute of Management Sciences, vol. 17, pp. 219-229, Nov. 1970.
- [Ja84] Jayant N.S. and Noll P. *Digital Coding of Waveforms*, Prentice-Hill, Englewood Cliffs, NJ, 1984.
- [Ko90] Kohonen T., "The Self-Organizing Map", *Proc. IEEE*, vol. 78, no. 9, pp. 1464-1480, Sep. 1990.
- [Kn92] Knagenhjelm P., "A recursive Design Method for Robust Vector Quantization", *Proc. Intl. Conf. Signal Processing Applications and Technology*, Boston, pp.948-954, Nov. 1992.
- [Kn93] Knagenhjelm P., "How good is your Index Assignment?", *Proc. IEEE - ICASSP-93*, Minneapolis, Minnesota, pp. 423-426, April 1993.
- [Kn95] Knagenhjelm P. and Erik Agrell, "The Hadamard Transform - A Tool for Index Assignment", Submitted to *IEEE Trans. Inform. Theory*.
- [Ku69] Kurtenbach A.J. and Wintz P.A, "Quantizing for Noisy Channels", *IEEE Trans. Comm. Tech.*, vol. 17, no. 2, pp. 291-302, April 1969.
- [La85] Lancaster P. and Tismenetsky M., *The Theory of Matrices*, Academic-Press, Orlando, 1985.
- [Li80] Linde Y., Buzo A. and Gray R.M., "An algorithm for Vector Quantization Design", *IEEE Trans. Comm.*, COM-28, pp.84-95, Jan. 1980.
- [Ll82] Lloyd S.P., "Least squares Quantization in PCM", *IEEE Trans. Inform. Theory*, IT-28, pp. 127-135, March 1982.

- [Lu84] Luenberger D.G., *Linear and Nonlinear Programming*, Addison-Wesley, Reading, MA, 1984.
- [Mc92] McLaughlin S.W., Ashley J.J and Neuhoff D.L., "The optimality of the Natural Binary Index Assignment", *Proc. of the Joint Dimacs/IEEE workshop on Coding and Quantization*, October 1992.
- [Pa82] Papadimitriou C.H. and Steiglitz K., *Combinatorial Optimization: Algorithms and Complexity*, Prentice-Hill, Englewood Cliffs, NJ, 1982.
- [Ry76] Rydbeck N. and Sundberg C.E.W., "Analysis of Digital Errors in Nonlinear PCM Systems", *IEEE Trans. Comm.*, COM-24, pp. 59-65, Jan. 1976.
- [Ta86] Taub H. and Schilling D.L., *Principles of Communication Systems*, McGraw-Hill, New-York, 1986.
- [Ta87] Taha H.A., *Operations Research - An Introduction*, Maxwell-Macmillan, New-York, 1987.
- [To67] Totty R.E. and Clark G.C., "Reconstruction Error in Waveform Transmission", *IEEE Trans. Inform. Theory*, IT-13 pp. 336-338, April 1967.
- [Vi79] Viterbi A.J. and Omura J.K., *Principles of Digital Communication and Coding*, McGraw-Hill, New-York, 1979.
- [Ze87] Zeger K. and Gersho A., "Zero Redundancy Channel Coding in Vector-Quantization", *Electronics Letters*, vol. 23, no. 12, pp. 654-656, June 1987.
- [Ze88] Zeger K. and Gersho A., "Vector Quantization Design for Memoryless Noisy Channels", *Proc. Intl. Conf. Comm.*, Philadelphia, PA, pp. 1593-1597, June 1988.
- [Ze90] Zeger K. and Gersho A., "Pseudo-Gray Coding", *IEEE Trans. Comm.*, vol. 38, no. 12, pp. 2147-2158, Dec. 1990.
- [Ze94] Zeger K. and Manzella V., "Asymptotic Bounds on Optimal Noisy Channel Quantization Via Random Coding", *IEEE Trans. Inform. Theory*, vol. 40, no. 6, pp. 1926-1938, Nov. 1994.

תכונות מטריצת המרחקים של הקוונטיזר הסקלרי האחיד

Properties of the uniform scalar quantizer distance matrix

In this appendix we introduce some properties of the distance matrix associated with the uniform scalar quantizer. These properties will be used in **Appendices B and C**.

Definition: The uniform scalar quantizer distance matrix of size N is the squared distance among its representing levels.

$$D = \Delta^2 \left\{ (i-j)^2 \right\}_{i,j=0}^{N-1} = \Delta^2 \cdot \begin{bmatrix} 0 & 1 & 4 & 9 & \dots & (N-1)^2 \\ 1 & 0 & 1 & 4 & & \\ 4 & 1 & 0 & 1 & \ddots & \\ 9 & 4 & 1 & 0 & \ddots & 4 \\ \vdots & & \ddots & \ddots & \ddots & 1 \\ (N-1)^2 & & & 4 & 1 & 0 \end{bmatrix} \quad (\text{A.1})$$

Where Δ is the distance between two consecutive reconstruction levels.

Throughout we assume $N \geq 3$.

Property 1: $\text{Rank}(D) = 3$

Proof: Note that

$$\begin{aligned} \frac{1}{\Delta^2} D &= \left\{ (i-j)^2 \right\}_{i,j=0}^{N-1} = \\ &= \left\{ i^2 \right\}_{i,j=0}^{N-1} + \left\{ j^2 \right\}_{i,j=0}^{N-1} - 2 \underline{\phi} \cdot \underline{\phi}^T \end{aligned} \quad (\text{A.2})$$

where $\underline{\phi} = [0 \ 1 \ \dots \ N-1]^T$.

Hence, D is the sum of three matrices, each of Rank=1.

Using the Perron-Frobenius theorem [La85, Section 15.3] for positive matrices we show that one eigenvalue of D is positive, two are negative, and the zero eigenvalue has a multiplicity of $N-3$.

Definition: A matrix D is primitive if all elements of D^k are strictly positive for some positive integer k .

Perron-Frobenius theorem: If a matrix D is nonnegative and primitive, then

1. D has a positive eigenvalue, r , with algebraic multiplicity 1.
2. The eigenvector associated with r has positive entries.
3. For any other eigenvalue of D , λ , $r > |\lambda|$.

Property 2: All elements of D^2 are strictly positive, hence D is primitive.

Proof: The general element of D^2 is:

$$[D^2]_{ij} = \Delta^4 \sum_{k=0}^{N-1} (i-k)^2 \cdot (k-j)^2 \quad (\text{A.3})$$

Since the size of D^2 is greater than three ($N \geq 3$), there is at least one strictly positive expression (for which $k \neq i$ and $k \neq j$).

Property 3: D has one positive eigenvalue and two negative eigenvalues for every size N . The sum of these three eigenvalues is zero.

Proof: The sum of all eigenvalues is zero since $\text{trace}\{D\} = 0$. Property 1 causes the number of nonzero eigenvalues to be three. Since D is primitive, it has a positive eigenvalue (Perron-Frobenius eigenvalue). This eigenvalue is strictly greater than the absolute value of all other eigenvalues. Therefore, the remaining nonzero eigenvalues are negative.

Property 4: The nonzero eigenvalues are:

$$\begin{aligned}\alpha_0 &= \Delta^2 \left[\frac{1}{12} N(N^2 - 1) + N \cdot S_N \right] \quad (\text{positive}) \\ \alpha_1 &= \Delta^2 \left[\frac{1}{12} N(N^2 - 1) - N \cdot S_N \right] \\ \alpha_2 &= -\Delta^2 \frac{1}{6} N(N^2 - 1)\end{aligned}\tag{A.4}$$

where $S_N = \sqrt{\frac{3N^4 - 10N^2 + 7}{240}}$

The corresponding eigenvectors:

$$\begin{aligned}\underline{u}_0 &= \left[\left(i - \frac{N-1}{2} \right)^2 \right]_{i=0}^{N-1} + S_N \cdot \underline{1} \\ \underline{u}_1 &= \left[\left(i - \frac{N-1}{2} \right)^2 \right]_{i=0}^{N-1} - S_N \cdot \underline{1} \\ \underline{u}_2 &= [2i]_{i=0}^{N-1} - (N-1) \cdot \underline{1}\end{aligned}\tag{A.5}$$

where $\underline{1} = [1 \ 1 \ \dots \ 1]^T$.

Proof: The Proof can be done by a brute-force calculation.

For example:

$$\begin{aligned}\frac{1}{\Delta^2} [D \cdot \underline{u}_2]_i &= \sum_{j=0}^{N-1} (i-j)^2 [2j - N + 1] = \\ &= 2 \sum_{j=0}^{N-1} j^3 + (1 - 4i - N) \sum_{j=0}^{N-1} j^2 + (2i^2 - 2i + 2iN) \sum_{j=0}^{N-1} j + i^2 N - i^2 N^2 = \\ &= \frac{1}{2} N^2 (N-1)^2 + \frac{1}{6} (1 - 4i - N)(N-1)N(2N-1) + \\ &\quad + (i^2 - i + iN)(N-1)N + i^2 N - i^2 N^2 = \\ &= -\frac{1}{6} (N-1)N(N+1) \cdot [2i - N + 1] = \\ &= \frac{1}{\Delta^2} \alpha_2 [\underline{u}_2]_i\end{aligned}\tag{A.6}$$

האופטימליות של הקוד הבינארי הטבעי עבור קוונטיזר סקלרי אחיד, מקור אחיד ותחת הערוץ הבינארי הסימטרי

The optimality of the Natural Binary Code Assignment for the Uniform Scalar Quantizer and a Uniform Source under the Binary Symmetric Channel

For the special case of a uniform scalar quantizer and a uniform source under the Binary Symmetric Channel, it is shown here that the Natural Binary Code offers the minimal Channel Distortion over all possible code assignments. This result is used in **Chapter 5**. The same result can be found in [Cr69],[Mc92], yet the optimization method as shown here is extended in Appendix C and Chapter 6 to give upper and lower bounds on general Vector Quantizers and general Memoryless Channels.

For the L -bit ($N = 2^L$ reconstruction levels) uniform scalar quantizer, we organize the N reconstruction levels in a column vector:

$$\underline{\rho} = \begin{bmatrix} \rho_0 \\ \rho_1 \\ \vdots \\ \rho_i \\ \vdots \\ \rho_{N-1} \end{bmatrix} = \frac{2}{N} \cdot \begin{bmatrix} -N/2 + 1/2 \\ 1 - N/2 + 1/2 \\ \vdots \\ i - N/2 + 1/2 \\ \vdots \\ N/2 - 1 + 1/2 \end{bmatrix} \quad (\text{B.1})$$

We denote the channel probability matrix in the case of an N levels quantizer by Q_N . The source probabilities matrix P is defined as $P = \text{diag}([p_0 \ p_1 \ \dots \ p_{N-1}])$, where $p_i = \text{Pr}\{\rho_i \text{ selected}\}$. Since the source is uniform $P = \frac{1}{N} \cdot I$, where I is the unity matrix. The distortion measure of interest is the quadratic distance:

$$d(\rho_i, \rho_j) = (\rho_i - \rho_j)^2 \quad (\text{B.2})$$

The channel distortion is (2.15):

$$\begin{aligned}
D_c &= \text{trace}\{P\pi Q_N \pi^T D\} = \\
&\Leftarrow \text{trace}\{AB\} = \text{trace}\{BA\}, \quad P = \frac{1}{N} \cdot I \\
&= \frac{1}{N} \text{trace}\{Q_N \pi^T D \pi\} = \\
&\Leftarrow \text{trace}\{AB\} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (A)_{ij} (B^T)_{ij} \\
&= \frac{1}{N} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (Q_N)_{ij} \left[(\pi \underline{\rho})_i - (\pi \underline{\rho})_j \right]^2 = \\
&= \frac{1}{N} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (Q_N)_{ij} [z_i - z_j]^2 = \\
&= \frac{1}{N} \sum_{i=0}^{N-1} z_i^2 \sum_{j=0}^{N-1} (Q_N)_{ij} + \frac{1}{N} \sum_{j=0}^{N-1} z_j^2 \sum_{i=0}^{N-1} (Q_N)_{ij} - \frac{2}{N} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (Q_N)_{ij} \cdot z_i \cdot z_j = \\
&= \frac{2}{N} (\underline{z}^T \underline{z} - \underline{z}^T Q_N \underline{z}) \tag{B.3}
\end{aligned}$$

where $\underline{z} = \pi \underline{\rho}$ is a permutation of the reconstruction levels.

In order to find lower and upper bounds for (B.3) over all possible assignments, it is suggested in [Mc92] to allow the entries of \underline{z} to be continuous, while preserving the first two moments. The distortion measure $d(\rho_i, \rho_j)$ is not affected by a constant offset addition to the entries of $\underline{\rho}$ (and \underline{z}). This allows us to choose the sum of the entries in \underline{z} to be zero.

The following optimization problem can be stated:

$$\begin{aligned}
\min_{\underline{z}} / \max_{\underline{z}} \quad & f(\underline{z}) = \underline{z}^T \underline{z} - \underline{z}^T Q_N \underline{z} \\
\text{s. t.} \quad & \underline{1}^T \underline{z} = 0 \\
& \underline{z}^T \underline{z} = \underline{\rho}^T \underline{\rho} = k^2 \\
& \Downarrow \\
\max_{\underline{z}} / \min_{\underline{z}} \quad & \tilde{f}(\underline{z}) = \underline{z}^T Q_N \underline{z} \\
\text{s. t.} \quad & \underline{1}^T \underline{z} = 0 \\
& \underline{z}^T \underline{z} = \underline{\rho}^T \underline{\rho} = k^2 \tag{B.4}
\end{aligned}$$

where $\underline{1}$ is a N -dimensional vector with unity entries, and k^2 is the variance of the reconstruction levels, $k^2 = \frac{(N+1)(N-1)}{3N}$

Using Lagrange multipliers:

$$L(\underline{z}, \mu_1, \mu_2) = \underline{z}^T Q_N \underline{z} + \mu_1 (\underline{z}^T \underline{z} - k^2) + \mu_2 (\underline{1}^T \underline{z}) \quad (\text{B.5})$$

and the derivative of $L(\underline{z}, \mu_1, \mu_2)$ w.r.t. \underline{z} :

$$\begin{aligned} \frac{\partial}{\partial \underline{z}} L(\underline{z}, \mu_1, \mu_2) &= 2\underline{z}^T Q_N + 2\mu_1 \underline{z}^T + \mu_2 \underline{1}^T = \\ &= 2\underline{z}^T (Q_N + \mu_1 I) + \mu_2 \underline{1}^T \end{aligned} \quad (\text{B.6})$$

one may obtain the following first order conditions:

$$\begin{aligned} a. \quad & (Q_N + \mu_1 \cdot I) \cdot \underline{z} = -\frac{\mu_2}{2} \cdot \underline{1} \\ b. \quad & \underline{1}^T \underline{z} = 0 \\ c. \quad & \underline{z}^T \underline{z} = k^2 \end{aligned} \quad (\text{B.7})$$

Multiplying (B.7a) by \underline{z}^T , we have:

$$\begin{aligned} \underline{z}^T \cdot (Q_N + \mu_1 \cdot I) \cdot \underline{z} &= -\frac{\mu_2}{2} \cdot \underline{z}^T \cdot \underline{1} \quad \underbrace{= 0}_{(\text{B.7b})} \\ \therefore \quad \underline{z}^T Q_N \underline{z} &= -\mu_1 k^2 \\ \therefore \quad \mu_1 &= -\frac{1}{k^2} \underline{z}^T Q_N \underline{z} \end{aligned} \quad (\text{B.8})$$

We define a normalized vector $\underline{w} = \frac{1}{k} \cdot \underline{z}$ and substitute (B.8) into (B.7a):

$$(Q_N - \underline{w}^T Q_N \underline{w} \cdot I) \cdot \underline{w} = -\frac{\mu_2}{2k} \cdot \underline{1} \quad (\text{B.9})$$

For the Binary Symmetric Channel, Q_N is symmetric and therefore has a unitary diagonalization:

$$Q_N = V \cdot \Lambda \cdot V^T \quad V \cdot V^T = I \quad (\text{B.10})$$

Since Q_N represents probabilities, the sum of any of its rows is one, so $\underline{1}$ is an eigenvector of Q_N .

$$Q_N \cdot \underline{1} = \underline{1} \quad (\text{B.11})$$

We may assume, therefore, that the first column of V is $\frac{1}{\sqrt{N}} \cdot \underline{1}$.

In order to simplify (B.9), we use now the following unitary transform $\underline{\xi} = V^T \underline{w}$. This vector has the following properties:

$$\begin{aligned} \text{a. } \underline{\xi}^T \underline{\xi} &= \underline{w}^T V V^T \underline{w} = \underline{w}^T \underline{w} = 1 \\ \text{b. } \xi_0 &= \frac{1}{\sqrt{N}} \cdot \underline{1}^T \underline{w} = 0 \end{aligned} \quad (\text{B.12})$$

Where ξ_0 is the first entry of $\underline{\xi}$.

The first order conditions in equation (B.9) are:

$$\begin{aligned} & \left(\overbrace{V \Lambda V^T}^{Q_N} - \underline{w}^T \overbrace{V \Lambda V^T}^{Q_N} \underline{w} \cdot I \right) \cdot \underline{w} = -\frac{\mu_2}{2k} \cdot \underline{1} \\ \therefore & \left(V \Lambda V^T - \underline{\xi}^T \Lambda \underline{\xi} \overbrace{V V^T}^I \right) \cdot \underline{w} = -\frac{\mu_2}{2k} \cdot \underline{1} \\ \therefore & V (\Lambda - \underline{\xi}^T \Lambda \underline{\xi}) \cdot V^T \underline{w} = -\frac{\mu_2}{2k} \cdot \underline{1} \\ \therefore & (\Lambda - \underline{\xi}^T \Lambda \underline{\xi}) \cdot \underline{\xi} = -\frac{\mu_2}{2k} \cdot V^T \underline{1} \end{aligned} \quad (\text{B.13})$$

The first row of V^T is $\frac{1}{\sqrt{N}} \cdot \underline{1}^T$, and the rest of its rows are orthogonal w.r.t. $\underline{1}^T$.

Therefore:

$$\therefore \overbrace{(\Lambda - \underline{\xi}^T \Lambda \underline{\xi} \cdot I)}^{\text{diagonal matrix}} \cdot \underline{\xi} = -\frac{\mu_2}{2k} \cdot V^T \cdot \underline{1} = \begin{bmatrix} -\frac{\mu_2 \sqrt{N}}{2k} \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (\text{B.14})$$

Observing that the first line of the diagonal matrix in (B.14) (the first eigenvalue of Q_N is $\lambda_0 = 1$),

$$\left[\lambda_0 - (\underline{\xi}^T \Lambda \underline{\xi}) \right] \cdot \xi_0 = -\frac{\mu_2 \sqrt{N}}{2k} \quad (\text{B.15})$$

and since ξ_0 is zero (B.12b), μ_2 is also zero. The Lagrange multiplier μ_2 represents the “sensitivity” of the optimization problem with respect to changes in the corresponding constraint. Namely, replacing (B.7b) with $\underline{1}^T \underline{z} = c$, for a sufficiently small range of c near zero, the optimization problem will have a solution point $\underline{z}(c)$ near the original point $\underline{z}(0)$. For each solution there is a corresponding value $\tilde{f}(\underline{z}(c))$ of (B.4), and this value can be regarded as a scalar function of c . It is shown in [Lu84, Section 10.7] that the derivative of this function w.r.t. c is μ_2 .

$$\left. \frac{d}{dc} \tilde{f}(\underline{z}(c)) \right|_{c=0} = \mu_2 \quad (\text{B.16})$$

We have just found that our optimization problem is not sensitive ($\mu_2 = 0$) to an addition of constants to all entries of \underline{z} , as was mentioned in (B.4).

The remaining lines of the diagonal matrix in (B.14)

$$\left[\lambda_i - (\underline{\xi}^T \Lambda \underline{\xi}) \right] \cdot \xi_i = 0, \quad i = 1, 2, \dots, N-1 \quad (\text{B.17})$$

Where λ_i are the eigenvalues of Q_N . Note that some entries of $\underline{\xi}$ must be non-zero because of (B.12a).

Assume some eigenvalue of Q_N , λ , has a multiplicity of m :

$$\lambda_l = \lambda_{l+1} = \dots = \lambda_{l+m-1} = \lambda \quad (\text{B.18})$$

A solution corresponding to this eigenvalue is as follows.

Equation (B.17) forces in this case $\lambda = \underline{\xi}^T \Lambda \underline{\xi}$. Moreover, only entries of $\underline{\xi}$ corresponding to those eigenvalues, ξ_i , $i = l, l+1, \dots, l+m-1$ can be nonzero.

The original vector \underline{z} ,

$$\underline{z} = k \cdot \underline{w} = k \cdot V \underline{\xi} \quad (\text{B.19})$$

is a linear combination of the columns of V (eigenvectors of Q_N). Since only ξ_i , $i = l, l+1, \dots, l+m-1$, are nonzero, \underline{z} is a linear combination of the eigenvectors corresponding with the eigenvalue λ . This vector \underline{z} should also comply with the variance constraint in (B.4).

Substitute (B.19) into (B.4)

$$\begin{aligned} f(\underline{z}) &= k^2 - k^2 \underline{\xi}^T V^T \cdot V \Lambda V^T \cdot V \underline{\xi} = \\ &= k^2 (1 - \underline{\xi}^T \Lambda \underline{\xi}) = k^2 (1 - \lambda) \end{aligned} \quad (\text{B.20})$$

One can see now that the minimal eigenvalue maximizes $f(\underline{z})$, while the maximal eigenvalue (not $\lambda_0 = 1$) minimizes it.

We turn now to calculate the eigenvalues and eigenvectors of Q_N . The calculation is done recursively in the number of bits - L .

For the single bit (two levels) uniform quantizer:

$$\begin{aligned} a. \quad Q_2 \begin{bmatrix} 1 \\ 1 \end{bmatrix} &= \begin{bmatrix} 1-q & q \\ q & 1-q \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \\ b. \quad Q_2 \begin{bmatrix} 1 \\ -1 \end{bmatrix} &= \begin{bmatrix} 1-q & q \\ q & 1-q \end{bmatrix} \cdot \begin{bmatrix} 1 \\ -1 \end{bmatrix} = (1-2q) \begin{bmatrix} 1 \\ -1 \end{bmatrix} \end{aligned} \quad (\text{B.21})$$

Assume that \underline{v} is an eigenvector of Q_N , i.e., $Q_N \underline{v} = \alpha \underline{v}$, it is possible to construct two eigenvectors for a quantizer with twice the number of level ($L+1$ bits):

a. *duplication*

$$\begin{aligned} Q_{2N} \begin{bmatrix} \underline{v} \\ \underline{v} \end{bmatrix} &= \begin{bmatrix} (1-q)Q_N & qQ_N \\ qQ_N & (1-q)Q_N \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ \underline{v} \end{bmatrix} = \\ &= \begin{bmatrix} Q_N \underline{v} \\ Q_N \underline{v} \end{bmatrix} = \alpha \begin{bmatrix} \underline{v} \\ \underline{v} \end{bmatrix} \end{aligned}$$

b. *negative-duplication*

$$\begin{aligned} Q_{2N} \begin{bmatrix} \underline{v} \\ -\underline{v} \end{bmatrix} &= \begin{bmatrix} (1-q)Q_N & qQ_N \\ qQ_N & (1-q)Q_N \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ -\underline{v} \end{bmatrix} = \\ &= \begin{bmatrix} (1-2q)Q_N \underline{v} \\ -(1-2q)Q_N \underline{v} \end{bmatrix} = (1-2q)\alpha \begin{bmatrix} \underline{v} \\ -\underline{v} \end{bmatrix} \end{aligned} \quad (\text{B.22})$$

The eigenvectors are constructed by either *duplication* of a smaller size eigenvector, corresponding to the same eigenvalue, or by *negative-duplication* corresponding to the eigenvalue multiplied by $1-2q$. Observing the recursive relations, one may verify that the eigenvectors matrix V is a Walsh-Hadamard matrix [CI85, Section 7.3].

Using these recursive relations the first three eigenvalue, eigenvectors sets are:

$$L=1 \quad 1, \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad 1-2q, \begin{bmatrix} 1 \\ -1 \end{bmatrix} \quad (\text{B.23a})$$

$$L=2 \quad 1, \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \quad 1-2q, \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} \quad 1-2q, \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \end{bmatrix} \quad (1-2q)^2, \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \end{bmatrix} \quad (\text{B.23b})$$

$$\begin{aligned}
L=3 \quad & 1, \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} & 1-2q, \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \\ 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} & 1-2q, \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \\ 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} & (1-2q)^2, \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \\ 1 \\ -1 \\ -1 \\ 1 \end{bmatrix} \\
& 1-2q, \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ -1 \\ -1 \\ -1 \\ -1 \end{bmatrix} & (1-2q)^2, \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \\ -1 \\ -1 \\ 1 \\ 1 \end{bmatrix} & (1-2q)^2, \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \\ -1 \\ 1 \\ -1 \\ 1 \end{bmatrix} & (1-2q)^3, \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \\ -1 \\ 1 \\ 1 \\ -1 \end{bmatrix}
\end{aligned} \tag{B.23c}$$

In general, there are $L+1$ distinct eigenvalues, $(1-2q)^m$ $m=0,1,\dots,L$, each with multiplicity $\binom{L}{m}$.

Using the known eigenvalues, we can now set bounds on $f(\underline{z})$ (B.20).

$$\begin{aligned}
& k^2 \cdot 2q \leq f(\underline{z}) \leq k^2 \left[1 - (1-2q)^L \right] \\
\therefore \frac{2(N+1)(N-1)}{3N^2} \cdot 2q \leq D_c \leq \frac{2(N+1)(N-1)}{3N^2} \left[1 - (1-2q)^L \right]
\end{aligned} \tag{B.24}$$

For low BER, the ratio between the upper and lower bounds is:

$$\lim_{q \rightarrow 0} \frac{\left[1 - (1-2q)^L \right]}{2q} = L \tag{B.25}$$

Up to this point we know that a vector \underline{z} which is an eigenvector of \underline{Q}_N , corresponding to the eigenvalue $1-2q$, minimizes the target function $f(\underline{z})$. An eigenvector corresponding to the eigenvalue $(1-2q)^L$ maximizes the target function.

The last statement to be verified is that the Natural Binary Code indeed results in an eigenvector corresponding to the eigenvalue $1 - 2q$.

For an L -bits quantizer, the eigenvectors of Q_N as constructed in (B.21) and (B.22), corresponding to the eigenvalue $1 - 2q$, are constructed by $L - 1$ duplications and a single negative-duplication.

For instance when the first duplication is negative we have,

$$\underline{v}_1 = [1 \ -1 \ 1 \ -1 \ 1 \ -1 \ \dots \ \dots \ 1 \ -1]^T \quad (\text{B.26})$$

Note that the elements of \underline{v}_1 are $(-1)^i$, $i = 0, 1, \dots, N - 1$.

When the second duplication is negative, the elements of \underline{v}_2 are $(-1)^{\lfloor i/2 \rfloor}$, $i = 0, 1, \dots, N - 1$, where $\lfloor i/2 \rfloor$ stands for integer division.

$$\underline{v}_2 = [1 \ 1 \ -1 \ -1 \ 1 \ 1 \ \dots \ \dots \ -1 \ -1]^T \quad (\text{B.27})$$

The last eigenvector corresponding to $1 - 2q$ is constructed such that the last duplication is negative, the first $N/2$ elements are +1, and the rest are -1.

$$\underline{v}_L = [1 \ 1 \ \dots \ 1 \ 1 \ -1 \ -1 \ \dots \ -1 \ -1]^T \quad (\text{B.28})$$

Note the similarity between the binary enumeration system and the entries of the L eigenvectors - \underline{v}_1 - "*Least Significant Bit*", $\underline{v}_2, \underline{v}_3, \dots, \underline{v}_{L-1}$ and \underline{v}_L - "*Most Significant Bit*".

For example, assigning the entries of $\underline{\xi}$ to be:

$$\begin{aligned} \xi_1 &= \frac{-1}{N}, \xi_2 = \frac{-2}{N}, \xi_3 = \frac{-4}{N}, \dots, \xi_L = \frac{-2^{L-1}}{N} = -\frac{1}{2} \\ \text{and } \xi_0 &= 0, \quad \xi_{L+1} = \dots = \xi_{N-1} = 0 \end{aligned} \quad (\text{B.29})$$

results in $\underline{z} = \underline{\rho}$, since:

$$\begin{aligned}
\underline{z} = \sum_{i=1}^L \xi_i \cdot \underline{v}_i &= \frac{1}{N} [-1 \ 1 \ -1 \ 1 \ -1 \ 1 \ \dots \ \dots \ -1 \ 1]^T + \\
&+ \frac{2}{N} [-1 \ -1 \ 1 \ 1 \ -1 \ -1 \ \dots \ \dots \ 1 \ 1]^T + \\
&\vdots \\
&+ \frac{1}{2} [-1 \ -1 \ \dots \ -1 \ -1 \ 1 \ 1 \ \dots \ 1 \ 1]^T = \underline{\rho}
\end{aligned} \tag{B.30}$$

These are the reconstruction levels of the Natural Binary Code assignment $\pi = I$.

For the same reasons, the positive values:

$$\begin{aligned}
\xi_1 &= \frac{1}{N}, \xi_2 = \frac{2}{N}, \xi_3 = \frac{4}{N}, \dots, \xi_L = \frac{2^{L-1}}{N} = \frac{1}{2} \\
\text{and } \xi_0 &= 0, \quad \xi_{L+1} = \dots = \xi_{N-1} = 0
\end{aligned} \tag{B.31}$$

are the linear coefficients of \underline{z} corresponding to the “down enumerating” Binary Code

$$\pi = \begin{bmatrix} 0 & 0 & \dots & 1 \\ & & \ddots & \vdots \\ 0 & 1 & & 0 \\ 1 & 0 & & 0 \end{bmatrix}$$

Moreover, assigning $\xi_1, \xi_2, \dots, \xi_L$ with every permutation of the L values (each can be chosen positive or negative) $\pm \frac{1}{N}, \pm \frac{2}{N}, \pm \frac{4}{N}, \dots, \pm \frac{2^{L-1}}{N} = \frac{1}{2}$ will result in a feasible permutation of $\underline{\rho}$ (B.1). Therefore, we can construct in this way $\frac{2^L}{\text{positive-negative}} \cdot \frac{L!}{\text{permutation}}$

optimal assignments, all with the same value of channel distortion D_c .

Worst assignment cannot be constructed in this way, since only one eigenvector exists for the eigenvalue $(1 - 2q)^L$.

◇

חסימים על עיוות הערוץ מעל כל השיבוצים האפשריים עבור ערוצים סימטריים
חסרי-זיכרון

Bounds on the Channel Distortion for Symmetric Memoryless Channels
over all possible assignments

In this appendix we introduce lower and upper bounds on the channel distortion under Symmetric Memoryless Channels over all possible assignments. These bounds are used in chapter 6, where numerical results are presented. We assume knowledge of the source probabilities matrix P , and the VQ codevectors distance matrix D .

Phase 1: At first we combine the matrices D and P into a single symmetric matrix.

The channel distortion is (2.15):

$$\begin{aligned}
 D_c &= \text{trace}\{P\pi Q_N \pi^T D\} = \\
 &\quad \Leftarrow \text{trace}\{AB\} = \text{trace}\{BA\} \\
 &= \frac{1}{2} [\text{trace}\{\pi Q_N \pi^T DP\} + \text{trace}\{DP\pi Q_N \pi^T\}] = \\
 &\quad \Leftarrow \text{trace}(A) = \text{trace}(A^T) \\
 &= \frac{1}{2} \text{trace}\{\pi Q_N \pi^T (DP + P^T D^T)\} = \\
 &\quad \Leftarrow \text{trace}\{AB\} = \text{trace}\{BA\} \\
 &= \frac{1}{2} \text{trace}\left\{Q_N \pi^T \underbrace{(DP + P^T D^T)}_{\hat{D}} \pi\right\} \tag{C.1}
 \end{aligned}$$

where π is an unknown permutation matrix.

The bounding technique is based on eigenvalues arguments. Instead of optimizing over the (discrete) family of matrices covering all possible assignments $\pi Q_N \pi^T$, we optimize over a wider (continuous) family. A fundamental step in this optimization procedure is that the matrix $\hat{D} = DP + P^T D^T$ is replaced by another symmetric matrix \tilde{D} , having $\underline{1} = [1 \ 1 \ \dots \ 1]^T$ as an eigenvector. This goal is achieved in phase 2.

Phase 2: We modify (C.1) so that the symmetric matrix \hat{D} is replaced by another symmetric matrix \tilde{D} , having the property $\tilde{D} \cdot \underline{1} = \beta \underline{1}$, where $\underline{1} = [1 \ 1 \ \dots \ 1]^T$.

In order to achieve this property we add to the symmetric matrix \hat{D} matrices of the following structure.

$$C_i = \begin{bmatrix} 0 & 0 & 1 & 0 & & 0 \\ 0 & 0 & 1 & 0 & & 0 \\ 0 & 0 & 1 & 0 & & 0 \\ 0 & \dots & 0 & 1 & 0 & \dots & \dots & 0 \\ 0 & 0 & 1 & 0 & & & & 0 \\ 0 & 0 & 1 & 0 & & & & 0 \\ 0 & 0 & 1 & 0 & & & & 0 \end{bmatrix}$$

↑ i -th column

(C.2)

Recalling that Q_N represents probabilities, the sum of any of its rows is one, so the vector $\underline{1}$ an eigenvector of Q_N .

$$\begin{aligned} Q_N \cdot \underline{1} &= \underline{1} \\ \therefore Q_N \cdot C_i &= C_i \end{aligned}$$
(C.3)

We show now that while preserving the symmetry of the matrix \hat{D} , we may add “Cross Structured” matrices $\alpha(C_i + C_i^T)$, where α is a scalar. This changes the expression $\frac{1}{2} \text{trace}\{Q_N \pi^T \hat{D} \pi\}$ in (C.1) just by the addition of α .

Property 1: Adding a scalar multiple of C_i to the matrix $\hat{D} = PD + DP$:

$$\begin{aligned} &\text{trace}\{Q_N \pi^T (\hat{D} + \alpha C_i) \pi\} = \\ &= \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{Q_N \pi^T C_i \pi\} = \\ &= \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{Q_N C_i \pi\} = \\ &= \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{\pi Q_N C_i\} = \\ &= \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{\pi C_i\} = \\ &= \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \end{aligned}$$
(C.4)

Similarly, for C_i^T :

$$\begin{aligned}
& \text{trace}\{Q_N \pi^T (\hat{D} + \alpha C_i^T) \pi\} = \\
& = \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{Q_N \pi^T C_i^T \pi\} = \\
& = \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{Q_N \pi^T C_i^T\} = \\
& = \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{C_i^T Q_N \pi^T\} = \\
& = \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha \cdot \text{trace}\{C_i^T \pi^T\} = \\
& = \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha
\end{aligned} \tag{C.5}$$

Applying both (C.5) and (C.6):

$$\begin{aligned}
& \frac{1}{2} \text{trace}\{Q_N \pi^T (\hat{D} + \alpha C_i^T + \alpha C_i) \pi\} = \\
& = \frac{1}{2} \text{trace}\{Q_N \pi^T \hat{D} \pi\} + \alpha
\end{aligned} \tag{C.6}$$

Algorithm: In order to achieve the desired property $\tilde{D} \cdot \underline{1} = \beta \underline{1}$, for some β , all rows of \tilde{D} must have the same sum of elements. Let us examine the effect of adding a “Cross Structured” matrix $\alpha(C_i + C_i^T)$ to a any matrix M of size $N \times N$. The sum of all rows but the i -th row is increased by α . The sum of the i -th row is increased by $(N + 1) \cdot \alpha$. Throughout the algorithm, a variable S is needed to store the sum of all “ α ” constant added to the r.h.s. of (C.1).

Pseudo-Code Listing for phase 2

Initialization: a. Set the matrix: $\tilde{D} \leftarrow \hat{D} = DP + P^T D^T$.

b. Set the sum of additive constants to zero: $S \leftarrow 0$.

Step 1: Calculate the sum of all rows.

Denote the sum of the i -th row by $S_i = \sum_{j=0}^{N-1} (\tilde{D})_{ij}$.

Step 2: Search all rows for the maximal sum of elements.

Assume that the row with the maximal sum is labeled k .

Step 3: For each row $i \neq k$:

a. Add the “*Cross Structured*” matrix $\tilde{D} \leftarrow \tilde{D} + \frac{1}{N}(S_k - S_i)(C_i + C_i^T)$.

b. Update $S \leftarrow S + \frac{1}{N}(S_k - S_i)$.

After execution of step 3, all rows have the same sum of elements.

By adding $N-1$ “*Cross Structured*” matrices we get a symmetric matrix where all rows have the same sum of elements, resulting in the matrix \tilde{D} , with the desired property $\tilde{D} \cdot \underline{1} = \omega_0 \underline{1}$.

Phase 3: The channel distortion is now:

$$D_c = \frac{1}{2} \text{trace} \{ Q_N \pi^T \tilde{D} \pi \} - S \quad (\text{C.7})$$

The symmetric channel probability matrix Q_N has a unitary diagonalization:

$$Q_N = V \cdot \Lambda \cdot V^T \quad V \cdot V^T = I \quad (\text{C.8})$$

We shall use the following theorem from [La85, Section 15.7].

Theorem: The Perron-Frobenius eigenvalue of a nonnegative symmetric matrix M with the property $M \cdot \underline{1} = \beta \underline{1}$ is β .

We arrange the eigenvalues in Λ to be in decreasing order. Therefore, using the above theorem, the first column of V is $\frac{1}{\sqrt{N}} \cdot \underline{1}$ and $\lambda_0 = 1$.

Substituting (C.8) into (C.7)

$$\begin{aligned} D_c &= \frac{1}{2} \text{trace} \{ V \Lambda V^T \pi^T \tilde{D} \pi \} - S = \\ &= \frac{1}{2} \text{trace} \{ \pi V \Lambda V^T \pi^T \tilde{D} \} - S = \end{aligned} \quad (\text{C.9})$$

The matrix πV is unitary for every permutation-matrix π , since $(\pi V)(\pi V)^T = \pi V V^T \pi^T = \pi \pi^T = I$. Moreover, for the first eigenvalue of Q_N , $\lambda_0 = 1$ (C.3), permutation does not affect its corresponding eigenvector:

$$\pi v_0 = \frac{1}{\sqrt{N}} \pi \underline{1} = \frac{1}{\sqrt{N}} \underline{1}.$$

In order to obtain the desired bounds we broaden the set of possible unitary matrices. Instead of optimizing D_c over all possible permutations (discrete), we bound the channel distortion by optimizing over all unitary matrices U , having $\underline{1}$ as the eigenvector corresponding to $\lambda_0 = 1$ (continuous).

The following optimization problem is to be solved:

$$\min_U / \max_U \left(\text{trace} \{ \Lambda U^T \tilde{D} U \} \right) \quad (\text{C.10})$$

where $UU^T = I$ and $\underline{u}_0 = \frac{1}{\sqrt{N}} \mathbf{1}$.

Note that the symmetric matrix \tilde{D} has also a unitary diagonalization $\tilde{D} = Z \cdot \Omega \cdot Z^T$, with the eigenvalues ω_i and corresponding eigenvectors \underline{z}_i . Moreover, \tilde{D} was constructed to have the eigenvector $\underline{z}_0 = \frac{1}{\sqrt{N}} \mathbf{1}$ with a corresponding eigenvalue ω_0 .

The eigenvalue ω_0 is the Perron-Frobenius eigenvalue of \tilde{D} . All other eigenvalues are arranged in decreasing order.

The matrix $\Theta = U^T Z$ is unitary, since $\Theta^T \Theta = Z^T U U^T Z = Z^T Z = I$. Moreover, the first

column of Θ is $\begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$, since both U and Z have orthonormal columns, and have

$$\underline{u}_0 = \underline{z}_0 = \frac{1}{\sqrt{N}} \mathbf{1}.$$

Substitute \tilde{D} into the optimization problem (C.10):

$$\begin{aligned} & \min_U / \max_U \left(\text{trace} \{ \Lambda U^T Z \cdot \Omega \cdot Z^T U \} \right) \\ & \therefore \min_{\Theta} / \max_{\Theta} \left(\text{trace} \{ \Lambda \Theta \cdot \Omega \cdot \Theta^T \} \right) \\ & \therefore \min_{\Theta} / \max_{\Theta} \left(\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \lambda_i \omega_j \theta_{ij}^2 \right) \end{aligned} \quad (\text{C.11})$$

where $\Theta \Theta^T = I$ and $\underline{\theta}_0 = [1 \ 0 \ \dots \ 0]^T$.

The sum of squares of the elements in each row and column of a unitary matrix is equal to 1.

We relax the constraints in (C.11) and state the following problem:

$$\begin{aligned}
& \min_{\Theta} / \max_{\Theta} \left(\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \lambda_i \omega_j \theta_{ij}^2 \right) \\
& \text{s.t.} \quad \sum_{i=0}^{N-1} \theta_{ij}^2 = 1 \quad j = 0, 1, \dots, N-1 \\
& \quad \quad \sum_{j=0}^{N-1} \theta_{ij}^2 = 1 \quad i = 0, 1, \dots, N-1
\end{aligned} \tag{C.12}$$

This is a standard Assignment problem [Ta87, Section 6.3]. An optimal solution for an Assignment problem is a permutation matrix Θ_{opt} , that has a single 1 in each row and column, while the rest of the matrix are zero. Such matrix is also unitary, thus solving (C.11), as long as the first column is $\underline{\theta}_0 = [1 \ 0 \ \dots \ 0]^T$.

Observing the target function in (C.11) $\sum_{i=0}^{N-1} \lambda_i \sum_{j=0}^{N-1} \omega_j \theta_{ij}^2$, we see that the permutation matrix Θ_{opt} does a one-to-one matching between the eigenvalues λ_i and ω_i (always matching λ_0 and ω_0 , since $\underline{\theta}_0 = [1 \ 0 \ \dots \ 0]^T$).

Since both λ_i and ω_i were sorted in decreasing order, the highest (lowest) possible value is obtained by matching the remaining eigenvalues in the same (reversed) order.¹

¹ It is easy to verify this for series of two elements: $a_1 \geq a_2$ and $b_1 \geq b_2 \Rightarrow (a_1 b_1 + a_2 b_2) - (a_1 b_2 + a_2 b_1) = (a_1 - a_2)(b_1 - b_2) \geq 0$.

Now assume $a_0 \geq a_1 \geq \dots \geq a_{N-1}$ and $b_0 \geq b_1 \geq \dots \geq b_{N-1}$, and we would like to maximize $S(\Pi) = \sum_{i=0}^{N-1} a_i b_{\Pi(i)}$ where $\Pi(i)$ is a permutation of the index i . If $b_{\Pi(i)} < b_{\Pi(i+1)}$, then $S(\Pi)$ would be larger if we switch them.

We may continue looking for such disordered constant $b_{\Pi(i)}$, while sorting them like in a **Bubble-Sort** algorithm. This sort results in $\Pi(i) = i$.

Same argument can be apply to check that minimum is achieved by $\Pi(i) = N - 1 - i$.

In conclusion, the minimum and maximum of the optimization problem are:

$$\lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \cdot \omega_{N-i} \leq \text{trace}\{\Lambda U^T \tilde{D} U\} \leq \lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \cdot \omega_i \quad (\text{C.13})$$

The upper and lower bounds are, therefore, obtained by the following algorithm:

Lower and Upper Bounds Pseudo-Code Listing

Note: First three step are similar to phase 2 algorithm.

Initialization: a. Set the matrix: $\tilde{D} \leftarrow \hat{D} = DP + P^T D^T$.

b. Set the sum of additive constants to zero: $S \leftarrow 0$.

Step 1: Calculate the sum of all rows.

Denote the sum of the i -th row by $S_i = \sum_{j=0}^{N-1} (\tilde{D})_{ij}$.

Step 2: Search all rows for the maximal sum of elements.

Assume that the row with the maximal sum is labeled k .

Step 3: For each row $i \neq k$:

a. Add the "Cross Structured" matrix $\tilde{D} \leftarrow \tilde{D} + \frac{1}{N}(S_k - S_i)(C_i + C_i^T)$.

b. Update $S \leftarrow S + \frac{1}{N}(S_k - S_i)$.

Step 4: Calculate the eigenvalues of the Channel Matrix Q , and sort them in decreasing order $\lambda_0 \geq \lambda_1 \geq \dots \geq \lambda_{N-1}$. For the Binary Symmetric Channel use App. B.

Remark: $\lambda_0 = 1$ with a corresponding eigenvector $\underline{1}$.

Lower and Upper Bounds Pseudo-Code Listing (cont.)

Step 5: Calculate the eigenvalues of \tilde{D} , and sort them in decreasing order $\omega_0 \geq \omega_1 \geq \dots \geq \omega_{N-1}$.

Remark: ω_0 has a corresponding eigenvector $\underline{1}$.

Step 6: Calculate the Upper and lower bounds from:

$$\lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \cdot \omega_{N-i} \leq \text{trace}\{\Lambda U^T \tilde{D} U\} \leq \lambda_0 \omega_0 + \sum_{i=1}^{N-1} \lambda_i \cdot \omega_i$$

Remark 1: A degree of freedom exists while constructing \tilde{D} . A scalar multiple of the

symmetric “All ones” matrix $F = \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & 1 & & 1 \\ \vdots & \vdots & & \vdots \\ 1 & 1 & \dots & 1 \end{bmatrix}$ can be added to \tilde{D} , while preserving

the symmetry property and keeping $\underline{1}$ as an eigenvector. Such an action does not affect the resulting lower and upper bounds.

Note the following properties, which arise from the orthogonality of U :

$$\begin{aligned} i = 0: \quad \underline{u}_0^T F \underline{u}_0 &= \frac{1}{N} \underline{1}^T F \underline{1} = N \\ i \neq 0: \quad \underline{u}_i^T F \underline{u}_i &= \underline{u}_i^T \begin{bmatrix} \underline{1}^T \\ \vdots \\ \underline{1}^T \end{bmatrix} \underline{u}_i = 0 \quad \Leftarrow \underline{u}_i \perp \underline{u}_0 \end{aligned} \tag{C.14}$$

Is it now shown that the optimization problem in (C.10) is changed only by an additive constant, thus not affecting the optimal matrix U .

$$\begin{aligned}
& \sum_{i=0}^{N-1} \lambda_i \underline{u}_i^T (\tilde{D} + \gamma F) \underline{u}_i = \\
& = \sum_{i=0}^{N-1} \lambda_i \underline{u}_i^T \tilde{D} \underline{u}_i + \gamma \sum_{i=0}^{N-1} \lambda_i \underline{u}_i^T F \underline{u}_i = \\
& \qquad \qquad \qquad \Leftrightarrow \underline{u}_i^T F \underline{u}_i = 0 \text{ for } i \neq 0 \\
& = \sum_{i=0}^{N-1} \lambda_i \underline{u}_i^T \tilde{D} \underline{u}_i + \gamma \lambda_0 \underline{u}_0^T F \underline{u}_0 = \\
& \qquad \qquad \qquad \Leftrightarrow \underline{u}_0^T F \underline{u}_0 = N \text{ and } \lambda_0 = 1 \\
& = \sum_{i=0}^{N-1} \lambda_i \underline{u}_i^T \tilde{D} \underline{u}_i + \gamma N
\end{aligned} \tag{C.15}$$

The factor γN is also added to S in step 3 of phase 2, thus it vanishes in (C.7).

Remark 2: The Rank of the matrix \tilde{D} is greater than the Rank of $(DP + P^T D^T)$ by at most 2. Observing that the matrix \tilde{D} can be written as:

$$\tilde{D} = DP + P^T D^T + \underbrace{\sum_{i=0}^{N-1} \alpha_i C_i}_A + \underbrace{\sum_{i=0}^{N-1} \alpha_i C_i^T}_B \tag{C.16}$$

Both matrices A and B have Rank=1.

Remark 3: For the case of a Uniform Scalar Quantizer and a Uniform Source, the lower and upper bounds obtained here coincide with those found in Appendix B.

Proof: In this case (see Appendix A):

$$\begin{aligned}
\hat{D} = DP + P^T D^T &= \frac{2}{N} D = \left(\frac{2}{N}\right)^3 \cdot \left\{ (i-j)^2 \right\}_{i,j=0}^{N-1} = \\
&= \frac{8}{N^3} \cdot \left[\left\{ i^2 \right\}_{i,j=0}^{N-1} + \left\{ j^2 \right\}_{i,j=0}^{N-1} - 2 \left\{ i \cdot j \right\}_{i,j=0}^{N-1} \right]
\end{aligned} \tag{C.17}$$

In phase 2, the sum of all rows is made equal. The term $\left\{ j^2 \right\}_{i,j=0}^{N-1}$ is common to all rows, and can be neglected.

Step 1: The sum of all rows:

$$\begin{aligned}
 S_i &= \frac{8}{N^3} \left[N \cdot i^2 - 2i \sum_{j=0}^{N-1} j \right] = \frac{8}{N^3} [N \cdot i^2 - N(N-1) \cdot i] = \\
 &= \frac{8}{N^2} [i^2 - (N-1) \cdot i] \quad i = 0, 1, \dots, N-1
 \end{aligned} \tag{C.18}$$

Step 2: The maximal sum is achieved at $i = 0$ and $i = N-1$.

We choose $k = 0$, hence $S_k = 0$.

Step 3: The sum of additive constants:

$$\begin{aligned}
 S &= -\frac{1}{N} \sum_{i=0}^{N-1} S_i = -\frac{8}{N^3} \left(\sum_{i=0}^{N-1} i^2 - (N-1) \sum_{i=0}^{N-1} i \right) = \\
 &= -\frac{8}{N^3} \left(\frac{(N-1)N(2N-1)}{6} - (N-1) \frac{(N-1)N}{2} \right) = \\
 &= \frac{4(N-1)(N-2)}{3N^2}
 \end{aligned} \tag{C.19}$$

The matrix \tilde{D} :

$$\begin{aligned}
 \tilde{D} &= \frac{8}{N^3} \cdot \left[\{i^2\}_{i,j=0}^{N-1} + \{j^2\}_{i,j=0}^{N-1} - 2\{i \cdot j\}_{i,j=0}^{N-1} - \sum_{i=0}^{N-1} [i^2 - (N-1) \cdot i] (C_i + C_i^T) \right] = \\
 &= \frac{8}{N^3} \cdot \left[\{i^2\}_{i,j=0}^{N-1} + \{j^2\}_{i,j=0}^{N-1} - 2\{i \cdot j\}_{i,j=0}^{N-1} - \sum_{i=0}^{N-1} [i^2 - (N-1) \cdot i] (C_i + C_i^T) \right] = \\
 &= \frac{8}{N^3} \cdot \left[(N-1)\{i\}_{i,j=0}^{N-1} + (N-1)\{j\}_{i,j=0}^{N-1} - 2\{i \cdot j\}_{i,j=0}^{N-1} \right] = \\
 &= \frac{8}{N^3} \cdot \left[\{[(N-1) - 2j] \cdot i\}_{i,j=0}^{N-1} + (N-1)\{j\}_{i,j=0}^{N-1} \right]
 \end{aligned} \tag{C.20}$$

The Rank of \tilde{D} is two, since it is a sum of two matrices, each of Rank=1.

The sum of the two nonzero eigenvalues is:

$$\omega_0 + \omega_a = \text{trace}\{\bar{D}\} = \frac{16(N-1)}{N^3} \sum_{i=0}^{N-1} i - \frac{16}{N^3} \sum_{i=0}^{N-1} i^2 = \frac{8(N-1)(N-2)}{3N^2} \quad (\text{C.21})$$

We used the notation ω_a , to point out that the order of the eigenvalues is not yet determined. \bar{D} was constructed such that the vector $\underline{1}$ is one of its eigenvectors. In order to calculate ω_0 , only the sum of the first line ($i = 0$) is needed:

$$\omega_0 = \frac{8(N-1)}{N^3} \cdot \sum_{j=0}^{N-1} j = \frac{4(N-1)^2}{N^2} \quad \Leftarrow (\text{C.21}) \quad (\text{C.22})$$

$$\omega_a = -\frac{4(N-1)(N+1)}{3N^2}$$

Note that ω_a is strictly negative. After sorting the eigenvalues, it will be placed as ω_{N-1} .

The eigenvalues of Q_N are known to be $(1-2q)^m$, $m = 0, 1, \dots, L$, (B.23), where L is the number of bits. The lower and upper bounds are therefore:

Lower bound:

$$D_c \geq \frac{1}{2} [\lambda_0 + \lambda_1(1-2q)] - S = \frac{2(N-1)(N+1)}{3N^2} \cdot 2q$$

Upper bound:

$$D_c \leq \frac{1}{2} [\lambda_0 + \lambda_1(1-2q)^L] - S = \frac{2(N-1)(N+1)}{3N^2} [1 - (1-2q)^L] \quad (\text{C.23})$$

as found in (B.24).

◇

האופטימליות של הקוד הבינארי הטבעי עבור קוונטיזר סקלרי אחד, מקור אחד ותחת הערוץ הבינארי הסימטרי עם קוד Hamming (7,4) לתיקון שגיאות

The optimality of the Natural Binary Code Assignment for a Uniform Scalar Quantizer and a Uniform Source under the Binary Symmetric Channel with a (7,4) Hamming error correcting code

In section 6.3.2 we consider the special case of a uniform scalar quantizer and a uniform source under the Binary Symmetric Channel (BSC), with (7,4) Hamming error correcting code [Ta86 Section 13.17], it is shown here that the Natural Binary Code (NBC) offers the minimal Channel Distortion over all possible code assignments.

For an L -bit ($N = 2^L$ reconstruction levels) uniform scalar quantizer, we organize the N reconstruction levels in a column vector (B.1):

$$\underline{\rho} = \begin{bmatrix} \rho_0 \\ \rho_1 \\ \vdots \\ \rho_i \\ \vdots \\ \rho_{N-1} \end{bmatrix} = \frac{2}{N} \begin{bmatrix} -N/2 + 1/2 \\ 1 - N/2 + 1/2 \\ \vdots \\ i - N/2 + 1/2 \\ \vdots \\ N/2 - 1 + 1/2 \end{bmatrix} \quad (\text{D.1})$$

In appendix B we proved that the NBC is the optimal assignment if the vector $\underline{\rho}$ is an eigenvector of the channel matrix Q , corresponding to the largest eigenvalue except for 1. In this appendix we show that this is indeed the case, also for Q_H - the channel matrix for the Binary Symmetric Channel, with (7,4) Hamming error correcting code.

The (7,4) Hamming code has a minimum distance of 3 for each pair of codewords, thus is capable of correcting a single bit error.

We denote the codeword of the index i by $c(i)$.

The codewords are:

Index i	Codeword $c(i)$	Index i	Codeword $c(i)$
0	0000000	8	1000111
1	0001110	9	1001001
2	0010101	10	1010010
3	0011011	11	1011100
4	0100011	12	1100100
5	0101101	13	1101010
6	0110110	14	1110001
7	0111000	15	1111111

Table D.1 - (7,4) Hamming Error Correcting Code

When a codeword $c(i)$ is transmitted, every 7-bit number k has a probability of $q^{H(k,c(i))}(1-q)^{7-H(k,c(i))}$ to appear at the receiver, where $H(k,c(i))$ is the Hamming distance between the codeword and the received number.

We examine a single entry of the channel transition matrix Q_H . Assume the VQ Encoder needs to transmit the index i . The Hamming codeword $c(i)$ is sent through the BSC. There are 8 possible BSC outputs that will cause the index j to appear at the receiver. These are the Hamming codeword $c(j)$ and its Hamming-1 distance neighbors. Each entry of Q_H is therefore a sum of 8 probabilities:

$$\begin{aligned} \{Q_H\}_{i,j} &= \text{Prob}\{\text{VQ Index } j \text{ received} \mid \text{VQ Index } i \text{ transmitted}\} = \\ &= \sum_{H(k,c(j))=1} \text{Prob}\{k \text{ received} \mid \text{codeword } c(i) \text{ transmitted}\} \end{aligned} \quad (\text{D.2})$$

The channel matrix Q_H has the following form:

$$Q_H = \underbrace{a \cdot I_{16}}_1 + \underbrace{d \cdot J_{16}}_2 + \underbrace{\begin{bmatrix} A & B & A & B \\ B & A & B & A \\ A & B & A & B \\ B & A & B & A \end{bmatrix}}_3 \quad (\text{D.3})$$

where:

$$I_{16} = \begin{bmatrix} 1 & & & 0 \\ & 1 & & \\ & & \ddots & \\ 0 & & & 1 \end{bmatrix} ; J_{16} = \begin{bmatrix} 0 & & & 1 \\ & & & \\ & & \ddots & \\ 1 & & & 0 \end{bmatrix}$$

$$A = \begin{bmatrix} c & b & b & c \\ b & c & c & b \\ b & c & c & b \\ c & b & b & c \end{bmatrix} ; B = \begin{bmatrix} b & c & c & b \\ c & b & b & c \\ c & b & b & c \\ b & c & c & b \end{bmatrix}$$

with:

$$\begin{aligned} a &= q_0 + 7q_1 - 4q_3 - q_4 - 3q_5 \\ b &= 3q_2 + q_3 + 4q_4 \\ c &= 4q_3 + q_4 + 3q_5 \\ d &= 7q_6 + q_7 - 3q_2 - q_3 - 4q_4 \end{aligned} \tag{D.4}$$

and $q_i = q^i(1-q)^{7-i}$, $i = 0, 1, \dots, 7$ is the probability of error in i bits of the codeword.

We now show that the columns of the Walsh-Hadamard matrix as described in Appendix B are the eigenvectors of each the three components of the matrix Q_H , denoted 1, 2 and 3 in (D.3).

We use a similar recursion methods as in (B.22).

Matrix 1: All columns are eigenvectors of the unity matrix I with a corresponding eigenvalue 1, since $I \cdot \underline{v} = \underline{v}$ for any vector \underline{v} .

Matrix 2: For a reverse-diagonal matrix of size 2, the following eigenvectors are verified:

$$\begin{aligned} J_2 \cdot \begin{bmatrix} 1 \\ 1 \end{bmatrix} &= \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \\ J_2 \cdot \begin{bmatrix} 1 \\ -1 \end{bmatrix} &= \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ -1 \end{bmatrix} = -1 \cdot \begin{bmatrix} 1 \\ -1 \end{bmatrix} \end{aligned} \tag{D.5}$$

Now assume the vector \underline{v} is an eigenvector of a reverse-diagonal matrix of size N , with a corresponding eigenvalue α . We can construct two eigenvectors of a reverse-diagonal matrix of size $2N$, by using:

Duplication:

$$J_{2N} \cdot \begin{bmatrix} \underline{v} \\ \underline{v} \end{bmatrix} = \begin{bmatrix} 0 & J_N \\ J_N & 0 \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ \underline{v} \end{bmatrix} = \alpha \cdot \begin{bmatrix} \underline{v} \\ \underline{v} \end{bmatrix}$$

Negative Duplication:

$$J_{2N} \cdot \begin{bmatrix} \underline{v} \\ -\underline{v} \end{bmatrix} = \begin{bmatrix} 0 & J_N \\ J_N & 0 \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ -\underline{v} \end{bmatrix} = -\alpha \cdot \begin{bmatrix} \underline{v} \\ -\underline{v} \end{bmatrix} \quad (\text{D.6})$$

Therefore, the matrix J_{16} has two eigenvalues: ± 1 , each with multiplicity 8. A Walsh-Hadamard eigenvector has a corresponding positive eigenvalues if it is constructed using an even number of negative duplications.

Matrix 3: The third matrix is constructed of two types of building blocks, both of size 4 and sharing the same eigenvectors. Their corresponding eigenvalue-eigenvectors are:

$$\begin{aligned} A \cdot \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} &= 2(b+c) \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} ; & A \cdot \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \end{bmatrix} &= 0 \cdot \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \end{bmatrix} \\ A \cdot \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} &= 0 \cdot \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} ; & A \cdot \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \end{bmatrix} &= 2(c-b) \cdot \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \end{bmatrix} \end{aligned} \quad (\text{D.7a})$$

$$\begin{aligned} B \cdot \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} &= 2(b+c) \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} ; & B \cdot \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \end{bmatrix} &= 0 \cdot \begin{bmatrix} 1 \\ -1 \\ 1 \\ -1 \end{bmatrix} \\ B \cdot \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} &= 0 \cdot \begin{bmatrix} 1 \\ 1 \\ -1 \\ -1 \end{bmatrix} ; & B \cdot \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \end{bmatrix} &= 2(b-c) \cdot \begin{bmatrix} 1 \\ -1 \\ -1 \\ 1 \end{bmatrix} \end{aligned} \quad (\text{D.7b})$$

Now assume that the vector \underline{v} is an eigenvector of both A and B, with a corresponding eigenvalues α and β respectively. We can construct four eigenvectors for matrix 3 (size 16).

$$\begin{aligned}
 \begin{bmatrix} A & B & A & B \\ B & A & B & A \\ A & B & A & B \\ B & A & B & A \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ \underline{v} \\ \underline{v} \\ \underline{v} \end{bmatrix} &= 2(\alpha + \beta) \begin{bmatrix} \underline{v} \\ \underline{v} \\ \underline{v} \\ \underline{v} \end{bmatrix} ; & \begin{bmatrix} A & B & A & B \\ B & A & B & A \\ A & B & A & B \\ B & A & B & A \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ -\underline{v} \\ \underline{v} \\ -\underline{v} \end{bmatrix} &= 2(\alpha - \beta) \begin{bmatrix} \underline{v} \\ -\underline{v} \\ \underline{v} \\ -\underline{v} \end{bmatrix} \\
 \begin{bmatrix} A & B & A & B \\ B & A & B & A \\ A & B & A & B \\ B & A & B & A \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ \underline{v} \\ -\underline{v} \\ -\underline{v} \end{bmatrix} &= 0 \cdot \begin{bmatrix} \underline{v} \\ \underline{v} \\ -\underline{v} \\ -\underline{v} \end{bmatrix} ; & \begin{bmatrix} A & B & A & B \\ B & A & B & A \\ A & B & A & B \\ B & A & B & A \end{bmatrix} \cdot \begin{bmatrix} \underline{v} \\ -\underline{v} \\ -\underline{v} \\ \underline{v} \end{bmatrix} &= 0 \cdot \begin{bmatrix} \underline{v} \\ -\underline{v} \\ -\underline{v} \\ \underline{v} \end{bmatrix}
 \end{aligned} \tag{D.8}$$

We apply (D.7) and (D.8) to construct the 16 eigenvectors of Matrix 3 of (D.3). Matrix 3 has the Walsh-Hadamard eigenvectors with the following corresponding eigenvalues:

$$\begin{aligned}
 \text{a. } 8(c+b) &\Leftrightarrow [1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1 \ 1]^T \\
 \text{b. } 8(c-b) &\Leftrightarrow [1 \ -1 \ -1 \ 1 \ -1 \ 1 \ 1 \ -1 \ -1 \ 1 \ -1 \ -1 \ 1 \ -1 \ 1 \ -1]^T
 \end{aligned} \tag{D.9}$$

The eigenvalue zero has a multiplicity of 14.

Using all the above information we may list the eigenvalues and corresponding eigenvectors of the channel matrix Q_H :

- There is one eigenvector (D.9a) constructed with no negative-duplication, and has eigenvalue 1.
- There are four eigenvectors constructed with one negative-duplication, all have eigenvalue $(a - d)$.
- There are six eigenvectors constructed with two negative-duplication, all have eigenvalue $(a + d)$. Note that d is negative, therefore this eigenvalue is smaller than $(a - d)$.

- There are four eigenvectors constructed with three negative-duplication, three have eigenvalue $(a-d)$. One eigenvector, (D.9b) has a corresponding eigenvalue $(a-d)+8(c-b)$. Note that $b > c$, therefore this eigenvalue is smaller than $(a-d)$.

There is one eigenvector constructed with four negative-duplication, and has eigenvalue $(a+d)$.

In conclusion, the channel matrix Q_H has four distinct eigenvalues (in decreasing order): 1, $(a-d)$, $(a+d)$, $(a-d)+8(c-b)$. The largest, except for 1, is $(a-d)$ and it corresponds to Walsh-Hadamard eigenvectors constructed with a single negative-duplication. In Appendix B, (B.30), we show that the representing-levels vector $\underline{\rho}$ is a linear combination of these eigenvectors.

This implies that $\underline{\rho}$ is an eigenvector of Q_H corresponding to the eigenvalue $(a-d)$.

This is the property that was needed to be verified. Therefore, the Natural-Binary-Code is also the optimal assignment for the Uniform Scalar Quantizer, Uniform Source and a Binary Symmetric Channel using the (7,4) Hamming Code.

אלגוריתם לשיבוץ תת-אופטימלי של אינדקסים בקוונטיזר וקטורי
עבור ערוצים סימטריים חסרי-זיכרון

Algorithm for Suboptimal Index Assignment in Vector Quantizers
for Symmetric Memoryless Channels

In this appendix we present an algorithm for suboptimal index assignment for Vector Quantizers, operating under Symmetric Memoryless Channels. The algorithm is also described in Chapter 7, and numerical results are presented in chapter 6. We assume knowledge of the Channel transition matrix Q_N , the source probabilities matrix P , and the VQ codevectors distance matrix D .

The optimization problem is, from (2.15):

$$\min_{\pi} D_c(\pi) = \text{trace}\{P\pi Q_N \pi^T D\} \quad (\text{E.1})$$

where π is an unknown permutation matrix.

In Appendix C, and in Section 5.3.2, we have shown that solving (E.1) is equivalent to solving the following optimization problem:

$$\min_{\pi} \text{trace}\{Q_N \pi^T \tilde{D} \pi\} \quad (\text{E.2})$$

where Q_N is the channel probability matrix and \tilde{D} is a symmetric matrix, having $\underline{1}$ as an eigenvector. \tilde{D} was constructed from both P and D , using an algorithm described as phase 2 in Appendix C.

The symmetric channel probability matrix Q_N has a unitary diagonalization:

$$Q_N = V \cdot \Lambda \cdot V^T \quad V \cdot V^T = I \quad (\text{E.3})$$

We arrange the eigenvalues in Λ to be in decreasing order, with the first column of V being $\frac{1}{\sqrt{N}} \cdot \underline{1}$, and the first eigenvalue is $\lambda_0 = 1$.

Substituting (E.3) into (E.2):

$$\min_{\pi} \text{trace}\{V \cdot \Lambda \cdot V^T \pi^T \tilde{D} \pi\} = \min_{\pi} \text{trace}\{\pi V \cdot \Lambda \cdot V^T \pi^T \tilde{D}\} \quad (\text{E.4})$$

The symmetric matrix \tilde{D} has also a unitary diagonalization:

$$\tilde{D} = Z \cdot \Omega \cdot Z^T \quad (\text{E.5})$$

with the eigenvalues ω_i and corresponding eigenvectors \underline{z}_i . Moreover, \tilde{D} was constructed to have the eigenvector $\underline{z}_0 = \frac{1}{\sqrt{N}} \mathbf{1}$ with a corresponding eigenvalue ω_0 .

The eigenvalue ω_0 is the Perron-Frobenius eigenvalue of \tilde{D} . Therefore it is positive and largest in absolute value. All eigenvalues are arranged in decreasing order.

The optimization problem is now:

$$\begin{aligned} \min_{\pi} \text{trace}\{\Lambda V^T \pi^T Z \Omega Z^T \pi V\} &= \\ &\Leftarrow \text{trace}\{AB\} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} A_{ij}^T B_{ij} \\ \min_{\pi} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \lambda_j \omega_i (Z^T \pi V)_y & \end{aligned} \quad (\text{E.6})$$

The matrix πV is unitary for every permutation-matrix π , since $(\pi V)(\pi V)^T = \pi V V^T \pi^T = \pi \pi^T = I$. Moreover, for the first eigenvalue of Q_N , $\lambda_0 = 1$, permutation does not affect its corresponding eigenvector: $\pi \underline{v}_0 = \frac{1}{\sqrt{N}} \pi \mathbf{1} = \frac{1}{\sqrt{N}} \mathbf{1}$.

Define a matrix Ψ as $\Psi = Z^T \pi V$. This matrix is also unitary for every permutation-matrix π , since $\Psi \Psi^T = (Z^T \pi V)(Z^T \pi V)^T = Z^T \pi V V^T \pi^T Z = Z^T \pi \pi^T Z = Z^T Z = I$.

Since the first column of both V and Z is $v_0 = z_0 = \frac{1}{\sqrt{N}} \mathbf{1}$, and the remaining columns are orthogonal to the vector $\mathbf{1}$, the structure of $\Psi = Z^T \pi V$ is:

$$\Psi = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & & & \\ \vdots & ? & & \\ 0 & & & \end{bmatrix} \quad (\text{E.7})$$

where the question mark represents unknown entries.

We have seen in Appendix C, (C.12), that if πV is replaced by a general unitary matrix, U , the minimal target function in (E.6) is achieved for:

$$\Psi^* = \begin{bmatrix} 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & & & 1 \\ \vdots & & & 1 & \\ 0 & & \dots & & \\ 0 & 1 & & & 0 \end{bmatrix} \quad (\text{E.8})$$

The matrix Ψ^* is not an outcome of a valid permutation matrix π in $\Psi = Z^T \pi V$. Therefore, we state an approximation by a general unitary matrix W . Replacing π with a general unitary matrix W , the minimal value for the target function is achieved for $W = Z \Psi^* V^T$. All entries of W are smaller in absolute value than 1: $|W_{ij}| \leq 1, \quad i, j = 0, 1, \dots, N-1$.

Next, we search for the permutation matrix "closest" to the matrix W , by solving a standard Assignment problem:

$$\begin{aligned} \min_{\pi} \quad & \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (1 - w_{ij}^2) \pi_{ij} \\ \text{s.t.} \quad & \sum_{j=0}^{N-1} \pi_{ij} = 1 \quad i = 0, 1, \dots, N-1 \\ & \sum_{i=0}^{N-1} \pi_{ij} = 1 \quad j = 0, 1, \dots, N-1 \\ & \pi_{ij} \geq 0 \end{aligned} \quad (\text{E.9})$$

The Weighting function $(1 - w_{ij}^2)$ is one of several possible weighting function and was found to perform well for the numerical examples we checked. Solving the Assignment problem (E.9), can be done by the Hungarian Method [Ta87 Section 6.3] known from Operations Research.

The outcome of the Assignment problem is a permutation matrix that can be used in the target function (E.1)

Remark 1:

For the Binary-Symmetric-Channel and small values of the Bit Error Rate q , it is possible to derive an asymptotically suboptimal index assignment by solving an optimization problem similar to (E.4). The result is an index assignment for an interval of channel Bit Error Rate: $0 \leq q \leq q_0$. The eigenvalues of the Channel matrix are $(1 - 2q)^l$, $l = 0, 1, \dots, L$, (B.23). In order to obtain the asymptotic behavior of these

eigenvalues, we note that: $\lim_{q \rightarrow 0} \frac{1}{-2q} ((1 - 2q)^l - 1) = l$.

We therefore replace the diagonal eigenvalues matrix Λ with an asymptotic diagonal

matrix $\hat{\Lambda} = \lim_{q \rightarrow 0} \frac{1}{-2q} (\Lambda - I)$.

The optimization solution is not affected by an addition of a constant (independent of the permutation matrix π) to the target function. Moreover, multiplying the target function by a negative constant will change the minimization problem to a maximization one.

The optimization problem, for small Bit Error Rates $q \rightarrow 0$, is changed as follows:

$$\begin{aligned}
& \min_{\pi} \text{trace}\{\pi V \cdot \Lambda \cdot V^T \pi^T \tilde{D}\} \\
& \therefore \max_{\pi} \left(-\frac{1}{2q} \text{trace}\{\pi V \cdot \Lambda \cdot V^T \pi^T \tilde{D}\} \right) \\
& \therefore \max_{\pi} \left(-\frac{1}{2q} \text{trace}\{\pi V \cdot \Lambda \cdot V^T \pi^T \tilde{D}\} - \text{trace}\{\tilde{D}\} \right) \\
& \therefore \max_{\pi} \left(-\frac{1}{2q} \text{trace}\{\pi V \cdot (\Lambda - I) \cdot V^T \pi^T \tilde{D}\} \right) \\
& \therefore \max_{\pi} \left(\text{trace}\left\{ \pi V \cdot \left[\lim_{q \rightarrow 0} \left(-\frac{1}{2q} (\Lambda - I) \right) \right] \cdot V^T \pi^T \tilde{D} \right\} \right) \\
& \therefore \max_{\pi} \text{trace}\{\pi V \cdot \hat{\Lambda} \cdot V^T \pi^T \tilde{D}\} \tag{E.10}
\end{aligned}$$

Note that for small values of q , the maximization in (E.10) is independent of the actual value of q .

Therefore, in order to obtain an asymptotically suboptimal (robust) index assignment, use the optimization method described starting in (E.4) to solve the problem:

$$\max_{\pi} \text{trace}\{\pi V \cdot \hat{\Lambda} \cdot V^T \pi^T \tilde{D}\}.$$

Remark 2 (complexity):

The complexity of the described algorithm is $O(N^3)$, since its phases are as follows:

1. Calculation of Eigenvalues and Eigenvectors for two Hermitian Matrices

[Go89 Section 8.2]: $O(N^3)$

2. Matrix multiplication: $O(N^2)$

3. Solving a standard Assignment Problem [Ta87 Section 6.3]: $O(N^3)$

תכנות ליניארי - הגדרות והמשפט היסודי

בעבודה זו, בפרקים 3 ו-7, נעשה שימוש בטכניקות של תכנות ליניארי (LP - Linear Programming). ניתן למצוא חומר מקיף בנושא בספרי הלימוד [Ta87], [Lu84]. בנספח זה נביא את ההגדרה של בעיית התכנות הליניארי, מונחים בסיסיים ואת המשפט היסודי של התכנות הליניארי. פתרון בעיית התכנות הליניארי נעשה ע"י אלגוריתם ה-Simplex וגזרותיו. בעיית תכנות ליניארי היא בעיית אופטימיזציה וקטורית, בה גם פונקציית המטרה וגם האילוצים הם ליניאריים במשתנים. הבעיה יכולה להיות בעיית מינימיזציה או מקסימיזציה, עם אילוצי שוויון ואי-שוויון.

$$\begin{aligned} \min / \max_{\underline{x}} \quad & \underline{c}^T \cdot \underline{x} \\ \text{s.t.} \quad & A_1 \cdot \underline{x} = \underline{b}_1 \\ & A_2 \cdot \underline{x} \geq \underline{b}_2 \\ & A_3 \cdot \underline{x} \leq \underline{b}_3 \end{aligned} \quad (\text{F.1})$$

כאשר המטריצות A_1, A_2, A_3 והוקטורים $\underline{c}, \underline{b}_1, \underline{b}_2, \underline{b}_3$ הנם בממדים מתאימים. ניתן להפוך באמצעות אלגברה פשוטה כל בעיית תכנות ליניארי לבעיית תכנות ליניארי בצורה סטנדרטית:

$$\begin{aligned} \min_{\underline{x}} \quad & \underline{c}^T \cdot \underline{x} \\ \text{s.t.} \quad & A \cdot \underline{x} = \underline{b} \\ & \underline{x} \geq \underline{0} \end{aligned} \quad (\text{F.2})$$

כאשר $\underline{0}$ הוא וקטור אפסים. מימדי המטריצות והוקטורים הם:

$$\underline{c}^{n \cdot 1}, \quad \underline{x}^{n \cdot 1}, \quad \underline{b}^{m \cdot 1}, \quad A^{m \cdot n} \\ \text{and } m < n \quad (\text{F.3})$$

A היא מטריצה עם מימד מלא ($\text{Rank}(A) = m$).

מכיוון שניתן להפוך כל בעיית תכנות ליניארי לצורה הסטנדרטית, מספיק להציע אלגוריתם לפתרון הצורה הזו.

נסתכל על מערכת המשוואות:

$$A \cdot \underline{x} = \underline{b} \quad (\text{F.4})$$

למערכת המשוואות יש n נעלמים ב- m משוואות ($m < n$), ולכן יש למערכת אינסוף פתרונות אפשריים.

הגדרה: פתרון קביל (Feasible Solution) - פתרון המקיים את האילוצים: $Ax = b$ ו- $x \geq 0$.
משפט: קבוצת הפתרונות הקבילים הנה קבוצה קמורה (Convex Set) [Lu84 סעיף 2.5].

הגדרה: פתרון בסיסי (Basic Solution) - פתרון למערכת המשוואות (F.4) שבו לפחות $n-m$ משתנים מן הוקטור x שווים לאפס.

ניתן למצוא את $\binom{n}{m}$ הפתרונות הבסיסיים ע"י בחירת m משתנים מן הוקטור x והשוואתם לאפס. שאר m המשתנים נקבעים ע"י פתרון מערכת המשוואות (m משוואות) הנותרת. כאשר אין למערכת המשוואות פתרון יחיד, מתקבל פתרון בסיסי מנוון. הטיפול בפתרונות מנוונים הוא מחוץ למטרת נספח זה.

הגדרה: פתרון בסיסי קביל (Feasible Basic Solution) - פתרון בסיסי המקיים גם את אילוץ ה-"אי-שליליות": $x \geq 0$.

לבעיית התכנות הליניארי ייתכנו המקרים הבאים:

1. אין פתרון קביל, כלומר מערכת האילוצים כוללת סתירות.
2. יש למערכת פתרונות קבילים אך אין לה פתרונות אופטימליים. לדוגמה עבור המערכת:

$$\begin{aligned} \min_x \quad & x_1 - x_2 + x_3 \\ \text{s.t.} \quad & x_1 + 2x_3 = 17 \\ & x_1, x_2, x_3 \geq 0 \end{aligned} \quad (\text{F.5})$$

3. יש למערכת פתרון קביל ואופטימלי.

המשפט היסודי של התכנות הליניארי:

עבור בעיית תכנות ליניארי במבנה סטנדרטי (F.2):

1. אם קיים פתרון קביל אזי קיים גם פתרון בסיסי קביל.
2. אם קיים פתרון קביל אופטימלי אזי קיים גם פתרון בסיסי קביל אופטימלי.

הערה: ייתכן מקרה בו קיים פתרון אופטימלי לא בסיסי, אולם המשפט מבטיח כי קיים פתרון בסיסי עם ערך פונקצית מטרה זהה.

המשפט היסודי מבטיח כי מספיק לחפש את הפתרון האופטימלי בפתרונות הבסיסיים שמספרם סופי. אלגוריתם ה-Simplex מבצע בכל איטרציה "קפיצה" בין פתרון בסיסי קביל לפתרון בסיסי קביל אחר עם ערך פונקציה מטרה נמוך יותר. ובכך מגיע תוך מספר צעדים סופי לאופטימום.

VECTOR AND SCALAR QUANTIZATION UNDER
CHANNEL-ERRORS

by
Gal Ben-David

VECTOR AND SCALAR QUANTIZATION UNDER CHANNEL-ERRORS

Research Thesis

Submitted in Partial Fulfillment of the Requirements
for the Degree of
Doctor of Science

by
Gal Ben-David

Submitted to the Senate of the Technion - Israel Institute of Technology

Sivan 5755

Haifa

June 1995

The work described herein was supervised by Prof. David Malah in the Faculty of Electrical Engineering

My sincere expression of gratitude to my supervisor, Prof. David Malah, for proposing the research subject and for his devoted guidance.

This paper concludes a wonderful period in which I earned my education in the Signal Processing Laboratory.

My deep thanks to Yoram Or-Chen for my first project and for his support. I would like to thank Ziva, Nimrod, Uri Avi and Tamara for the great time we spent together.

I would like to thank to the Wolf foundation for the generous support by the Dr. Moshe Gilboa Memorial scholarship

To Renata and Dan-Ilan

Table of Contents

Abstract	1
Table of symbols and notations	3
Chapter 1 - Introduction	6
1.1 - Subject description	6
1.2 - Objective and main results	7
1.3 - Thesis organization	8
Chapter 2 - Background and Literature survey	9
2.1 - Vector Quantization - Introduction	9
2.1.1 - Optimality conditions for Vector Quantizer - Quantizer design	11
2.1.2 - Vector Quantizer design - Kohonen approach	13
2.2 - Vector Quantization under channel errors	14
2.3 - Reducing Channel Distortion by proper Index Assignments	19
2.3.1 - Index Assignment by Index Switching algorithm	19
2.3.2 - Index Assignment by Simulated Annealing algorithm	20
2.4 - Adaptation of Partition Cells and Representation Vectors	21
2.4.1 - Scalar Quantizer	21
2.4.2 - Vector Quantizer	22
2.4.3 - Vector Quantizer design - Kohonen approach	23
2.5 - Mutual design of Quantizer structure and Index Assignment	24
Chapter 3 - Bounds on the Channel Distortion over all possible input sources	26
3.1 - Introduction	26
3.2 - Performance bounds over all possible input sources	26
3.3 - Improvement of the Performance bounds using Moment information	30
3.3.1 - Improvement of the Performance bounds using Power constraint	31
3.4 - Performance bounds for low Bit Error Rate	33
3.5 - The Uniform Scalar Quantizer and Natural Binary Code Under the Binary Symmetric Channel	36
3.6 - Summary	40

Table of Contents (continued)

Chapter 4 - Linear scaling of Vector Quantizer for reducing the Distortion due to Channel Errors	41
4.1 - Introduction	41
4.2 - Description of Linear Scaling in Vector Quantizers	41
4.3 - Scaled Vector Quantizer	44
4.3.1 - Scaled Scalar Quantizer	46
4.4 - Numerical results	47
4.4.1 - Laplacian PDF-optimized Scalar Quantizer	47
4.4.2 - Generalized-Gaussian PDF-optimized Scalar Quantizer	49
4.4.3 - Gaussian PDF-optimized Vector Quantizer	51
4.5 - Summary	52
Chapter 5 - The optimality of the Natural Binary Code for the Uniform Scalar Quantizer and the Uniform Source under Binary Symmetric Channel	53
5.1 - Introduction	53
5.2 - Comparing with Gray Code	53
5.3 - Proof summary	56
5.3.1 - Problem description and formulation of a continuous problem	56
5.3.2 - Solving the optimization problem using Lagrange multipliers	58
5.3.3 - Comparing the lower bounds with the performance due to the Natural Binary Code	60
5.4 - Summary	61

Table of Contents (continued)

Chapter 6 - Bounds on the Channel Distortion over all Possible Index Assignments (Symmetric Memoryless Channel)	62
6.1 - Introduction	62
6.2 - Bounds summary	62
6.2.1 - Problem description	63
6.2.2 - Modifications in the Weighted Distance Matrix	63
6.2.3 - Formulation of a continuous problem	65
6.2.4 - Solving the continuous problem	66
6.3 - Numerical results	68
6.3.1 - Uniform Scalar Quantizer and Uniform source under the Binary Symmetric Channel	68
6.3.2 - Uniform Scalar Quantizer and Uniform source under the Binary Symmetric Channel using (7,4) Hamming Error Correcting Code	70
6.3.3 - Uniform Scalar Quantizer Optimized for the Gaussian source under the Binary Symmetric Channel	71
6.3.4 - Uniform Scalar Quantizer Optimized for the Gaussian source under the Binary Symmetric Channel using (7,4) Hamming Error Correcting Code	73
6.3.5 - Gaussian PDF optimized Vector Quantizer under the Binary Symmetric Channel	74
6.4 - Summary	75
Chapter 7 - Suboptimal algorithm for Index Assignment (Symmetric Memoryless Channels)	76
7.1 - Introduction	76
7.2 - Algorithm Summary	76
7.3 - Using the algorithm for Asymptotic results	79
7.4 - Summary	80
Chapter 8 - Summary, conclusions and Proposals for further research	81
8.1 - Summary	81
8.2 - Proposals for further research	82
References	84

Table of Contents (continued)

Appendix A - Properties of the uniform scalar quantizer distance matrix	87
Appendix B - The optimality of the Natural Binary Code Assignment for the Uniform Scalar Quantizer and a Uniform Source under the Binary Symmetric Channel	90
Appendix C - Bounds on the Channel Distortion for Symmetric Memoryless Channels over all possible assignments	100
Appendix D - The optimality of the Natural Binary Code Assignment for a Uniform Scalar Quantizer and a Uniform Source under the Binary Symmetric Channel with a (7,4) Hamming error correcting code	112
Appendix E - Algorithm for Suboptimal Index Assignment in Vector Quantizers for Symmetric Memoryless Channels	118
Appendix F - Linear Programming - Definitions and main results	123

Abstract

Vector Quantization (VQ) systems (or Scalar Quantization as a special case) are widely implemented in Source-Coding Applications. VQ can be found in many modern speech and image coding systems. A Vector Quantizer divides the set of all possible input signals (vectors) into a finite set of Partition Cells, where each cell is represented by a Representation Vector. VQ is a method for Lossy Compression. Due to quantization, part of information existing in the original signal is lost, and the reconstructed signal is not identical to the original. The difference between the original signal and its reconstruction is known as the Quantization Distortion.

A VQ based communication system consists of two parts: Encoder and Decoder. The Encoder (prior to the digital channel) examines the input vector and decides to which partition cell it belongs. Both the Encoder and Decoder keep an identical table of Representation Vectors. Each vector is assigned with a Channel Index. This index is transmitted through the channel, and the Decoder pulls out a corresponding Representation Vector.

VQ design is based on the knowledge of the statistics of the signal source. In practice, the design is based on a Training Sequence collected at the source. "Classical" analysis and design methods of VQ systems assume that no error occurs in the digital channel. For practical channels, a channel Error-Correcting-Code is used, which in many situations cause the Channel-Errors effects to be negligible.

In many other cases the effect of Channel Errors is significant, and better performance can be obtained by using Vector Quantizers that take channel errors into consideration.

One of the goals of this work is to examine the effect of channel errors on the performance of given VQ systems. A channel error causes an incorrect index to appear at the decoder. The decoder then reconstructs an incorrect vector. The distance between the reconstructed vector and the vector that should have been reconstructed, is known as the Channel Distortion. The distance between the (erroneous) reconstructed vector and the original input vector is the Total (Overall) distortion. In this work we assume a memoryless channel, while some of the results are being

applicable only to the special, yet useful, case of the Binary-Symmetric-Channel (BSC).

In addition to finding bounds on the performance of given VQ systems, two factors affecting Channel distortion are examined. The first is the constellation of the Vector (and Scalar) Quantizer in terms of Partition Cells and Representation Vectors. The other element is the assignment of channel indices to the Reconstruction Vectors.

In the first part of the this work upper and lower bounds on the Channel-Distortion over all possible input sources are obtained. Several numerical examples are shown for demonstration. For the special case of a Uniform Scalar Quantizer (USQ), Natural Binary Code (NBC) and a BSC, the upper bound coincides with the lower bound. Moreover, for the same case, the Channel Distortion is practically independent of the number of bits of the quantizer. In other cases the gap between the upper and lower bounds could be large and their knowledge does not give enough information to estimate the system performance. For these cases, tighter bounds are presented for a reduced set of possible sources, characterized by source moments, and especially power constraints. Asymptotical bounds for the BSC for small channel bit error rate ($q \rightarrow 0$) are also presented.

For USQ of 4-bits and more, we also show that the channel distortion due to the NBC is better than the average distortion over all possible index assignments for all possible source.

In previous works found in the literature, necessary conditions for optimal VQ design in the presence of Channel-Errors are given. These conditions give rise to a complicated design procedure, producing a library of different quantizers, each for a different error rate of the channel. Storing such a library, in both the Encoder and Decoder, results in costly memory requirements. In this work we present a simple suboptimal approach. We suggest to linearly scale the Partition Cells and Reconstruction Vectors as a function of the channel error rate. The design procedure is much simpler, most of it coincides with the classical (no channel errors) design. The memory requirements of the proposed system is much less demanding. Numerical examples are shown, demonstrating that the performance loss compared with the optimal approach is relatively small.

An important factor influencing Channel Distortion is the assignment of indices to the reconstruction vectors. Generally, the goal is to make channel errors do as less damage as possible. There is a huge number of possible index assignments. For a VQ with N representation vectors there are $N!$ possible assignments, causing an exhaustive search over all possible assignment to be practically impossible.

For the special case of the USQ, Uniform Source, and the BSC, the NBC assignment is shown to be optimal.

Lower and Upper bounds on the Channel Distortion over all possible assignments for any Memoryless channel are then presented.

We conclude this work by developing a suboptimal algorithm for index assignment for a VQ operating under Symmetric Memoryless Channels. The complexity of the algorithm is shown to be of $O(N^3)$, and it performs better than the most extensively used algorithm - Index Switching, whose complexity is $O(N^4)$.

In numerical examples, the bounds over all possible index assignments are compared with 10,000 random assignments, and for two cases also with the proposed suboptimal assignment. The limited random search is found to be insufficient due to the vast number of possible assignments (for a merely 4-bit quantizer we examined 10^4 assignment out of the possible $2 \cdot 10^{13}$). For the special case of USQ and a uniform source, the lower bound coincides with the optimal assignment.

For a typical case examined by simulation, the Channel-Distortion due to the assignment given by the proposed algorithm is about 8dB lower than the average distortion over all possible index assignments. For the same case, the distortion due to the index switching algorithm is about 1dB higher than the proposed algorithm.