

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

۱۰۸۳۱۱

دانشگاه تبریز

دانشکده مهندسی برق و کامپیوتر

پایان نامه برای دریافت درجه کارشناسی ارشد
مهندسی برق (گرایش مخابرات)

جداسازی بازتاب از تصویر توسط الگوریتمهای جداسازی
کور منابع با استفاده از ویژگیهای محلی

کتابخانه مخابرات تبریز

استاد راهنما: دکتر مسعود رضا آقابزرگی

استاد مشاور: دکتر محمد تقی صادقی

پژوهش و نگارش: محمد حسین صادقی

۱۳۸۷ / ۹ / ۲۳

مهرماه ۱۳۸۷

۱۰۸۳۱۱

تقدیم به

پدرم

او که در مسولیت پدرانہ اش ذرہ ای تردید نکرد

مادرم

مادری که محبت بی دریغش ہمراه زندگیم بوده و هست

اثر پیش روی، آموخته‌های در حد بضاعت ناچیز نگارنده، از دریای بیکران
ولی نعمتان بیشمار است؛ که هر چند از فرط کثرت ذکر نامشان مقدور نیست
لیک طلایه داران شان را از فرط حدت نقششان، یارای گزیر از حمد نمی باشد:

دکتر مسعود رضا آقا بزرگی

دکتر محمد تقی صادقی

و دیگر عزیزانی که مراد اجزای این پروژه یاری رسانده اند.

گرامیگانی که این ساگرد کوچک خود را وادارشان می بیند و سپاس الطافشان را

فرض می گیرد. توفیق رفیقشان باد.



مدیریت تحصیلات تکمیلی

صور تجلسه دفاعیه پایان نامه دانشجوی
دوره کارشناسی ارشد

شناسه: ب/ک/۳

جلسه دفاعیه پایان نامه تحصیلی آقای/ خانم: محمد حسین صادقی دانشجوی کارشناسی ارشد
رشته/گرایش: برق - مخابرات
تحت عنوان: جداسازی بازتاب از تصویر توسط الگوریتم های جداسازی کور منابع با استفاده از ویژگی های
محلی
و تعداد واحد: ۶ در تاریخ ۱۳۸۷/۷/۲۴ با حضور اعضای هیأت داوران (به شرح ذیل) تشکیل گردید.
پس از ارزیابی توسط هیأت داوران، پایان نامه با نمره: به عدد ۱۹،۴۰ به حروف نوزده و شصت درصد
و درجه مالی مورد تصویب قرار گرفت.

<u>عنوان</u>	<u>نام و نام خانوادگی</u>	<u>امضاء</u>
استاد/ استادان راهنما:	دکتر مسعود رضا آقابرگی	
استاد/ استادان مشاور:	دکتر محمد تقی صادقی	
متخصص و صاحب نظر داخلی:	دکتر حمیدرضا ابوطالبی	
متخصص و صاحب نظر خارجی:	دکتر محمد رضا احمدزاده	

نماینده تحصیلات تکمیلی دانشگاه (ناظر)

نام و نام خانوادگی: سید منصور بیدکی

امضاء

چکیده

امروزه جداسازی کور منابع یکی از مسائل پایه ای و اساسی در حوزه پردازش سیگنال شده است. دلیل محبوبیت و این افزایش روبه افزون را می توان در کور بودن ماهیت آن جست. عدم نیاز به اطلاعات اولیه در مورد منابع و یا سیستم ترکیب کننده و همچنین مشاهدات سیگنالهای طبیعی که ترکیباتی از سیگنالهای پایه هستند، همگی از مواردی است که در افزایش کاربرد جداسازی کور منابع نقش اساسی ایفا کرده است. از جمله کاربردهای این گونه تکنیک های کور می توان به پردازش صوت و تصویر، سیگنالهای مخابراتی و پردازش سیگنالهای پزشکی اشاره کرد که در آن سیگنالهای مشاهده شده، ترکیباتی از چندین سیگنال مطلوب هستند. از جمله فرضیات ساده ای که می توان در نظر گرفت، فرض استقلال منابع است که می توان به صراحت بیان کرد که بیشتر مشاهدات طبیعی از ترکیب منابع مستقل ایجاد شده اند.

در هنگام تهیه تصویر از یک سطح شفاف نیمه منعکس کننده مانند شیشه، معمولاً تصویر حاصل شامل دو تصویر خطی منطبق بر هم می باشد: تصویر پشت سطح شفاف یا زمینه و تصویر حاصل از بازتاب اجسام بر روی آن جداسازی انعکاس با استفاده از یک تصویر ورودی مساله حاد و بغرنجی می باشد. خصوصاً هنگامی که اطلاعاتی در مورد تصاویر ترکیبی وجود ندارد. اهمیت این موضوع زمانی احساس می شود که تصویر منعکس شده موجب ایجاد ابهام و اختلالاتی در آنالیز تصویر اصلی گردد.

این پایان نامه به بررسی مساله جداسازی بازتاب تصاویر اجسام از یک تصویر مخلوط مشاهده شده می پردازد. در این میان فرضیاتی که در نظر گرفته می شود، همان فرضیات جداسازی کور منابع یا بطور واضح تر استقلال منابع است. با این تفاوت که در مساله مورد نظر با شرایط کمینه تعریف روبرو هستیم؛ یعنی تعداد مشاهدات کمتر از تعداد منابع است (در اینجا تعداد منابع دو عدد و تعداد مشاهدات یک تصویر مخلوط است). این موضوع علاوه بر اینکه به مساله کلیت

بیشتری می دهد، آن را نیز پیچیده تر می سازد. در این پایان نامه ابتدا به شرح بدست آوردن بردارهای پایه برای تصویر با استفاده از تکنیک ICA پرداخته می شود و سپس با استفاده از روش ارزش گذاری به ضرایب بردارهای پایه به تخمین تصویر اصلی از بازتاب می پردازیم. در ادامه با محاسبه همبستگی میان تصویر بازیابی شده و بانک داده، تصویر واقعی زمینه را بدست می آوریم. تصویر منعکس شده را با اعمال تکنیک ICA در فضای تصویر مخلوط شده، تصویر اصلی و تصویر کاهش یافته تصویر اصلی از مخلوط بدست می آوریم

فصل اول: مقدمه	۱
۱-۱- تاریخچه	۲
۲-۱- جداسازی کور منابع	۳
۳-۱- آنالیز مولفه های مستقل	۹
۴-۱- طرح تحقیق حاضر	۱۳
فصل دوم: آمارگان	۱۵
۱-۲- مقدمه	۱۶
۲-۲- اطلاعات قبلی (پیش زمینه) برای ICA	۱۷
۱-۲-۲- ممانهای متغیر های تصادفی	۱۷
۲-۲-۲- آنتروپی و اطلاعات متقابل	۲۰
۳-۲-۲- استقلال ، واگرایی KL و آنتروپی	۲۶
فصل سوم: ICA و انواع روشهای آن	۲۹
۱-۳- مقدمه	۳۰
۲-۳- تعریف ICA	۳۱
۳-۳- مدل داده های ICA	۳۲
۱-۳-۳- فرضیات در مدل داده ها	۳۴
۲-۳-۳- پردازش داده ها	۳۵
۴-۳- رسیدن به ICA	۳۶
۱-۴-۳- الگوریتم Comon برای ICA	۳۶
۲-۴-۳- الگوریتم Jutten - Herault	۳۷
۳-۴-۳- مدل عصبی برای ICA ارائه شده توسط Oja و Hyvarinen	۳۸
۴-۴-۳- روش ماکزیمم سازی اطلاعات	۳۸
۵-۳- الگوریتم info-max	۳۹
۶-۳- الگوریتم FAST ICA	۴۷

۵۳	فصل چهارم: الگوریتم جداسازی تصاویر دارای انعکاس
۵۴	۱-۴- مقدمه
۵۶	۲-۴- عملکرد ICA در ارتباط با دو منبع
۵۶	۱-۲-۴- خروجی ICA در ارتباط با سیگنالها
۵۸	۲-۲-۴- ویژگی های سیگنالهای مخلوط شده
۶۰	۳-۲-۴- نامخلوط سازی سیگنالها
۶۱	۳-۴- استخراج کور منابع مستقل
۶۱	۱-۳-۴- تبدیل خطی
۶۲	۲-۳-۴- بردار نامخلوط کنندگی
۶۳	۳-۳-۴- ضرب داخلی
۶۶	۴-۳-۴- محاسبه تابع احتمال با استفاده از هیستوگرام
۶۷	۵-۳-۴- قضیه حد مرکزی (CLT)
۶۸	۶-۳-۴- استخراج منابع با توجه به خواص سیگنالها
۶۹	۴-۴- جداسازی کور یک تصویر دارای انعکاس
۷۰	۱-۴-۴- تخمین تصویر اصلی (زمینه) از تصویر مخلوط (تصویر دارای بازتاب)
۷۱	۲-۴-۴- بدست آوردن بردارهای پایه با استفاده از الگوریتم ICA
۷۳	۳-۴-۴- الگوریتم بازآوری تصویر انعکاس یافته
۷۷	۴-۴-۴- معیار ANMRR
۸۰	۵-۴-۴- نتایج شبیه سازی
۸۳	فصل پنجم: نتیجه گیری و پیشنهادها
۸۴	۱-۵- نتیجه گیری
۸۶	۲-۵- پیشنهادها
۸۷	پیوست
۹۲	فهرست منابع و ماخذ

- شکل ۱-۲: تغییرات آنتروپی پرتاب سکه..... ۲۲
- شکل ۲-۲: شماتیک شبکه انتقال بردار تصادفی..... ۲۴
- شکل ۳-۲: نمایش آنتروپی حاشیه ای، شرطی و اطلاعات متقابل..... ۲۵
- شکل ۱-۳: شبکه عصبی مورد استفاده در اجرای ICA توسط الگوریتم Info-Max..... ۴۱
- شکل ۲-۳: بلوک دیاگرام شبکه عصبی با حلقه فیدبک برای به روز رسانی ماتریس وزن W در الگوریتم Info-Max..... ۴۶
- شکل ۱-۴: مثالی از عملکرد ICA..... ۵۶
- شکل ۲-۴: مقایسه نمودار پراکندگی منابع و مخلوطهای آن و مفهوم استقلال..... ۵۸
- شکل ۳-۴: نمایش هیستوگرام سیگنالهای منابع و مخلوطهای متناظر با آن و مفهوم توزیع گوسی در طبیعت..... ۵۹
- شکل ۴-۴: نمایش تبدیل خطی فضای S به فضای X و نحوه انتخاب بردار وزن..... ۶۵
- شکل ۵-۴: بیان یک قسمت از تصویر اصلی بر اساس مجموع ضرایبی از بردارهای پایه..... ۷۰
- شکل ۶-۴: نمونه هایی از بردارهای پایه بدست آمده از روش ICA..... ۷۳
- شکل ۷-۴: نمایش تاثیر اندازه و طول بردارهای پایه در بازسازی تصویر..... ۷۵
- شکل ۸-۴: نمایش عملکرد الگوریتم حذف بردارهای پایه با ضرایب کوچک و حذف الگوهای ایجاد شده با استفاده از فیلتر پایین گذر..... ۷۶
- شکل ۹-۴: یافتن تصویر اصلی در بانک تصاویر و در نظر گرفتن آن به عنوان دومین مشاهده..... ۷۷
- شکل ۱۰-۴: عملکرد الگوریتم حذف بردارهای پایه بر روی تصاویر واقعی..... ۸۱
- شکل ۱۱-۴: نحوه اعمال ICA و استخراج بازتاب از تصویر مخلوط..... ۸۲
- شکل ۱۲-۴: نمونه ای دیگر از عملکرد الگوریتم حذف بردارهای پایه با ضرایب کوچک..... ۸۳

فصل اول

مقدمه

۱-۱- تاریخچه

جداسازی کور منابع^۱ یکی از مسائل پایه ای در پردازش سیگنال است که از اواسط دهه ۸۰ مورد توجه قرار گرفت. امکان حل مسأله BSS نخستین بار در سال ۱۹۸۵ و توسط B.Ans و C.Jutten و J.Herault در یک کاربرد بیولوژیکی مطرح شد. ایده اولیه در حدود سال ۱۹۸۲ هنگامی به وجود آمد که این تیم روی مدل کردن سیگنالهای حرکتی مفصل کار می کردند. آنها مشاهده کردند که در هنگام انتقال اطلاعات مربوط به سرعت و مکان زاویه ای یک مفصل به مغز، اطلاعات مربوط به سرعت و مکان توسط دو سیگنال عصبی مختلف به مغز ارسال می شود، ولی هر دوی این سیگنال ها ترکیباتی از اطلاعات مکان و سرعت است و در نتیجه مغز حتما باید روشی برای جداسازی این اطلاعات داشته باشد. به عبارتی مغز باید به طریقی بتواند سیستم معکوس را تنها از روی مشاهدات تخمین بزند. آنها در نهایت روشی برای تخمین پارامترهای سیستم معکوس یافتند که بعدها به الگوریتم^۲ HJ معروف شد. کارایی و سادگی الگوریتم HJ در حل یک مسأله ظاهرا پیچیده، به تدریج توجه محققان دیگر را نیز به این مسأله جلب کرد. برخی از این محققین مانند Lacoume در ابتدا تنها برای آنکه اشتباه بودن ادعای HJ را نشان دهند به کار روی این مسأله پرداختند، که این تلاش ها در نهایت منجر به اثبات ریاضی قابل حل بودن BSS و ارائه الگوریتم های بهتری برای آن شد. این موضوع در ابتدا مورد توجه افرادی که در زمینه

^۱ Blind Source Separation

^۲ Herault-Jutten

شبکه های عصبی کار می کردند قرار نگرفت، زیرا در آن زمان موضوعات جدید و متنوعی در این شاخه مطرح شده بود. در حالی که در حوزه پردازش سیگنال، خصوصا در فرانسه و اروپا مساله جداسازی کور به شدت از مقبولیت خاصی برخوردار گردید. اکنون بسیاری از کنفرانس های پردازش سیگنال و شبکه های عصبی، بخش هایی را به جداسازی کور منابع اختصاص داده اند. در ابتدا ایده جداسازی کور، آنالیز مولفه های مستقل (ICA)^۱ نامیده شد. زیرا تا زمانی که ترکیب های غیر خطی مطرح نبودند، یافتن مولفه های مستقل از روی مشاهدات باعث جداسازی منابع می شد. اما پس از مطرح شدن ترکیب های غیر خطی، مساله جداسازی کور منابع و آنالیز مولفه های مستقل به تدریج از یکدیگر فاصله گرفتند [۲۱].

۱-۲- جداسازی کور منابع

جداسازی کور منابع یک تکنیک محاسباتی برای نمایش فاکتورهای پنهانی^۲ است که خروجی آن، مجموعه های زیر لایه ای^۳ از اندازه گیری ها یا سیگنال ها هستند. بطور کلی این مسائل خیلی کلی هستند و راه حل های متنوعی برای آن پیشنهاد شده است. پایه ای ترین روش آماری BSS، آنالیز مولفه های مستقل ICA می باشد. ICA یک مدل آماری است که داده های چند متغیری مشاهده شده را به طور متنوعی از یک پایگاه داده بزرگ نمونه ها می گیرد و در آن فرض می شود مخلوط ها، ترکیباتی خطی یا غیرخطی از برخی متغیرهای پنهان نامعلوم مستقل با ضرایب مخلوط کنندگی نامشخص هستند. متغیرهای نهفته، غیرگوسی و متقابلا مستقل هستند که آنها را مولفه های مستقل داده های مشاهده شده یا منابع می نامند. بنابراین ICA را می توان

¹ Independent Component Analysis

² Hidden Factors

³ Underlie Sets

یک تعمیمی از آنالیز مولفه های اصلی^۱ یا آنالیز فاکتورها^۲ در نظر گرفت. ICA تکنیک بسیار توانمندی است و در هنگامی که روشهای کلاسیک کاملاً شکست خورده اند قادر به یافتن منابع است. در بسیاری موارد، اندازه گیری ها به صورت یک مجموعه از سیگنالهای موازی یا زنجیره های زمانی در نظر گرفته می شوند. مخلوط هایی از اصوات همزمان یا صداهای انسان که توسط چندین میکروفن جمع آوری شده اند، اندازه گیریهای سیگنال مغز از چندین سنسور EEG^۳، چندین سیگنال رادیویی که همزمان به گوشی همراه می رسند یا چندین سری زمانی موازی به دست آمده از فرایند صنعتی همگی مثالهای متنوعی از کاربرد ICA در این زمینه هستند. کلمه جداسازی کور منابع برای بیان عدم وجود اطلاعات از نحوه ترکیب سیگنالهای منابع، استفاده شده است. BSS و ICA هر دو جزء روشهای نظارت نشده^۴ می باشند. همچنین یادگیری نظارت نشده یک مفهوم عمیقی است که می توان از چشم اندازه های متفاوتی از جمله علوم روانشناسی و شناختی تا مهندسی به آن نگاه کرد و اغلب به آن یادگیری بدون معلم گفته می شود. این موضوع بر این امر دلالت دارد که یادگیری انسانی، حیوانی یا سیستم هوش مصنوعی محیط اطراف را مشاهده می کند و بر پایه این مشاهدات، رفتارش را بدون داشتن تطابق بین مشاهدات گرفته شده با پاسخ مطلوب گرفته شده (یادگیری نظارت شده) یا بدون حتی گرفتن هیچ اشاره ای در مورد خوبی پاسخ گرفته شده (یادگیری تقویتی)^۵ تطبیق می دهد. به طور معمول نتایج یادگیری نظارت نشده یک تفسیر جدید یا نمایشی از داده های مشاهده شده است که منجر به بهبود پاسخ یا تصمیم آینده می شود. این بستگی به BSS و ICA دارد که فاکتورهایی را بیابد که داده ها را به طور با معنی شرح دهد [۵۴و۳].

¹ Principal Component Analysis

² Factor Analysis

³ Electroencephalography

⁴ Unsupervised Learning

⁵ Reinforcement Learning

به عنوان یک نکته، داده‌ها در هر کار پردازش داده با معنی، واقعا تصادفی نیستند و توسط فرایند فیزیکی تولید شده‌اند که باعث محدودیت پیچیدگی می‌شوند. هر نوع تصمیم‌گیری روی داده‌ها مانند طبقه‌بندی یا رگرسیون^۱ روی این مجموعه متغیرها، تاثیر پذیر از عوامل زیرلایه‌ای یا علت‌ها است. آموزش نظارت‌نشده یک روش عملی برای یافتن متغیرهای تولیدی زیر لایه است.

یادگیری نظارت‌نشده همچنین ارتباط عمیقی با شبکه‌های عصبی طبیعی و مصنوعی دارد که به نظر می‌رسد، مکانیزم پایه‌ی آن در تطابق سنسوری است. مقایسه عقلانی بودن یادگیری نظارت‌شده در مقابل یادگیری نظارت‌نشده، در یادگیری سیستم عصبی سخت است. زیرا یادگیری و قدرت سیستم نظارت‌شده از تطبیق سنسوری آن سرچشمه می‌گیرد. اگر این فرضیه را بپذیریم که یادگیری بر پایه اصلاح پیوندگاهی^۲ است و قوانین یادگیری نظارت‌شده مانند پس انتشار خطا^۳ به طور محلی روی سطوح پیوندگاه اجرا می‌شود، بنابراین زیر لایه زیست‌شناختی (بیولوژیکی)^۴ آن سازگاری بیشتری با مدل یادگیری نظارت‌نشده دارد [۵ و ۶].

در محاسبات عصبی، دو دسته بندی کلاسیک برای مدل‌های یادگیری نظارت‌نشده وجود دارد که اولی تعمیمی از آنالیز مولفه‌های اصلی و آنالیز فاکتورها است و دومی کدینگ بردارهای یادگیری^۵ یا مدل‌های خوشه‌بندی هستند که بر پایه یادگیری رقابتی^۶ می‌باشند. اولین دسته بندی از روشهای یادگیری نظارت‌نشده که از PCA یا FA منشعب می‌شود، یک زیر لایه کاهش یافته از ترکیبات خطی متغیرهای ورودی اصلی می‌دهد. بیشتر قوانین یادگیری PCA بر پایه مدل‌های عصبی مولفه‌ای آن می‌باشد. یک مدل جدید در این دسته بندی، مولفه‌های مستقل

¹ Regression

² Synaptic modification

³ back propagation

⁴ Biological substrate

⁵ Learning vector coding

⁶ Competitive learning

است که تا حداکثر امکان افزونی^۱ بین متغیرهای نهفته را کاهش می دهد که منجر به آنالیز مولفه های مستقل و جداسازی کور منابع می شود.

همچنین ICA مثالی از نمایش مساله یادگیری نظارت نشده در چهار چوب مدل تولیدی احتمالی^۲ است. فهم عملکرد بازسازی و تخمین یک مدل که داده ها را با جمله هایی از متغیرهای نهفته شرح می دهد از درون طبیعت و ساختار حقیقی خود داده ها امکان پذیر است. بنابراین عملگرهایی مانند پیشگویی و فشرده سازی آسانتر و بادقت بیشتر توجیه پذیر می شوند [۷و۸و۹]. در طول دو دهه گذشته، جداسازی کور منابع (سیگنال) بخصوص در پردازش سیگنال بطور کامل مطالعه شده است. در جداسازی کور منابع، تلاش می شود تا سیگنالهای منابع مستقل $(\{s_k(i)\}, i=1, \dots)$ از بردارهای داده (x_k) استخراج شود. در اینجا بردارهای پایه ICA، $a(i)$ ها، معمولا چندان جالب و مورد توجه نبودند. چنین تکنیک های کوری برای مثال در پردازش آرایه^۳، بهبود گفتار^۴ و مخابرات کاربرد داشته است. در جداسازی و فقی منابع [۱۰] یک ماتریس جداساز، B_k را طوری به روز رسانی می کند که بردار:

$$Y_k = B_k X_k \quad (1-1)$$

یک تخمین $(Y_k = \hat{S}_k)$ از سیگنالهای منابع مستقل اصلی می شود. در الگوریتم های کور نمی توان بدون فرضیات اضافی، دامنه سیگنالهای منابع $S_k(i)$ ها را از مدل تعیین کرد. اغلب در جداسازی منابع به جای نرمالیزه کردن بردارهای پایه $a(i)$ ، فرض می شود که سیگنال هر منبع $S_k(i)$ دارای واریانس واحدی است. در چندین الگوریتم جداسازی کور، بردارهای داده X_k ابتدا با یک پیش پردازش سفید (کروی سازی)^۵ می شوند. یعنی ماتریس کواریانس آنها ماتریسی واحد می شود. روشهای متنوعی از سفید سازی با جزئیات بیشتر در ادامه بحث خواهد شد. بعد از پیش

¹ Redundancy

² Probabilistic Generative Models

³ Array processing

⁴ Speech enhancement

⁵ Whitening (Sphearing)

سفید سازی ماتریس جداساز B_k در معادله (۱-۱) می تواند متعامد در نظر گرفته شود. یعنی:
 $B_k B_k^T = I_M$. چنین محدودیت های کمکی که خاصیت سفید بودن را باقی نگه می دارد،
 الگوریتم های جداساز ثانویه را ساده تر می سازد و همچنین واریانس منابع تخمین زده شده
 $\hat{S}_k(i)$ را به طور اتوماتیک به واحد نرمالیزه می سازد.

یک مشکل عملی در الگوریتم جداسازی منابع و ICA این است که نمی توان مستقیما یا
 با اندازه گیری درجه استقلال از روی اطلاعات متقابل، میزان قابل اعتماد بودن شرط استقلال را
 تایید کرد. زیرا چگالی های احتمال مورد بحث نامعلومند. برای رفع این مشکل از توابع تباین^۱
 استفاده می شود. توابع تباین از روی فرضیات در نظر گرفته شده مساله به عنوان مثال از استقلال
 منابع به دست می آید. این توابع باید توسط ماتریس جداساز مینیمم شود که نمونه هایی از آن
 در [۱۱] معرفی شده است. حتی محاسبات این توابع تباین نسبتا خوب، به تخمین آمارگان مراتب
 بالای داده ها، نیاز دارند که اغلب به الگوریتمهای جداسازی وفقی پیچیده ای منجر می شوند.
 خوشبختانه، عموما استفاده از ساده ترین آمارگان مرتبه بالا که کورتوسیس^۲ نامیده می شود کافی
 است. کورتوسیس یک تابع انباشته ای مرتبه چهارم با تاخیر زمانی صفر می باشد. برای i امین
 سیگنال $s(i)$ کورتوسیس نرمال نشده به صورت زیر تعریف می شود:

$$cum[s(i)^4] = E\{s(i)^4\} - 3[E\{s(i)^2\}]^2 \quad (۲-۱)$$

کورتوسیس معیاری برای سنجش پیک دار یا تخت بودن داده نسبت به یک توزیع نرمال است. به
 عبارت دیگر مجموعه داده ها با کورتوسیس زیاد، میل به داشتن پیک (قله) در نزدیکی میانگین
 دارند که شیب قله آن نسبتا شدید و امتداد (دم) آن طولانی (کشیده) است. داده های با
 کورتوسیس کم، میل به داشتن قله تختی در نزدیکی میانگین دارند [۱۲].

¹ Contrast function

² Kurtosis

اگر $s(i)$ گوسی باشد کورتوسیس آن $cum[s(i)^4] = 0$ است. سیگنالهای منابعی که کورتوسیس منفی دارند اغلب زیر گوسی^۱ نامیده می شوند. معمولا توزیع های احتمال منابع طبیعی، تخت تر از توزیع گوسی است. برای مثال می توان به سیگنال Bimodal اشاره کرد. منابع با کورتوسیس مثبت (منابع فوق گوسی^۲) به طور معمول توزیعی دارند که دم (امتداد) طولانی تر و پیک تیزتری نسبت به توزیع گوسی دارند [۱۳ و ۱۴]. تقسیم بندی توابع به فوق گوسی و زیر گوسی اهمیت زیادی دارد. زیرا قابلیت جداسازی بسیاری از الگوریتمها شدیداً وابسته به این خواص است. به ویژه برای بردارهای ورودی سفید شده می توان نشان داد که اگر علامت کورتوسیس در معادله (۳-۱)

برای همه سیگنالهای منابع $s_k(i), i = 1, 2, \dots, M$ یکسان باشد تابع تباین ساده [۳]

$$J_1(y) = \sum_{j=1}^M |cum[y(i)^4]| = \sum_{j=1}^M |E\{s(i)^4\} - 3[E\{s(i)^2\}]^2| \quad (3-1)$$

توسط یک ماتریس جداساز B در معادله (۱-۱) ماکزیمم می شود.

برای دو بردار متعامد ورودی سفید شده X و ماتریس جداساز، توان خروجی برابر است با:

$$E\{y(i)^2\} = 1 \quad (4-1)$$

و در نتیجه: $cum[y(i)^4] = E\{y(i)^4\} - 3$.

بنابراین اگر جمع ممانهای چهارم یعنی:

$$J_2(y) = \sum_{i=1}^M E\{y(i)^4\} \quad (5-1)$$

برای منابعی که کورتوسیس منفی داشته باشد مینیمم و برای منابعی با کورتوسیس مثبت

ماکزیمم گردد، معیار معادله (۳-۱) ماکزیمم می شود [۱۲ و ۱۵].

¹ Sub-Gaussian

² Super-Gaussian

۱-۳- آنالیز مولفه های مستقل

آنالیز مولفه های مستقل ICA به عنوان یک محدوده استاندارد از پردازش سیگنالهای مربوطه و در زمینه آنالیز داده ها پدیدار شده است. تکنیک ICA تلاش می کند تا مسائل جداسازی کور منابع را در حالتی که سیگنالهای سنسور، مخلوط هایی از ترکیبات سیگنالهای منابع مستقل نامعلوم هستند حل کند. این تکنیک که از آمارگانهای مراتب بالا برروی داده های غیرگوسی استفاده می کند را می توان به صورت تعمیمی از PCA در نظر گرفت. آنالیز مولفه های مستقل معمولا در کاربردهای متنوعی از پردازش آرایه ها، مخابرات، پردازش سیگنالهای پزشکی و پردازش گفتار مورد نیاز است [۱۶ و ۱۷].

از جهتی نقطه ی شروع ICA، نا همبسته سازی خواص PCA است. تقریبا (بدون در نظر گرفتن جزئیات)، بجای نیاز به ضرایب یک بسط خطی از بردارهای داده ناهمبسته در PCA، این بردارها در ICA باید متقابلا مستقل (یا تا حد امکان مستقل) باشند. به همین دلیل است که از آمارگان های مرتبه بالا در تعیین بسط ICA استفاده می شود که در بسیاری از موارد نمایش مفیدتری از داده ها نسبت به PCA ارائه می کند.

به طور کلی در روشهای اخیر تحقیقات شبکه های عصبی، علاوه بر PCA، شکلهای مختلفی از آموزشهای نظارت نشده مورد مطالعه قرار گرفته است. چنین تکنیک هایی اغلب روشهای PCA غیرخطی نامیده می شوند [۱۸]. دلیل اصلی برای این علاقه مندی این است که اگر چه PCA در تقریب داده های ورودی با معیار حداقل مربعات خطا بهینه است اما نتایجی که ارائه می کند چندان در شرح بعضی ویژگیها و مشخصات داده ها سودمند نیست. در PCA داده ها توسط پایه های نرمال متعامد نمایش داده می شوند که فقط توسط آمارگان مرتبه ی دوم داده های ورودی تعیین می شوند. این میزان اطلاعات برای داده های گوسی مناسب و کافی است. هر چند

داده های غیرگوسی شامل مقدار زیادی اطلاعات اضافی در آمارگانهای مرتبه بالاتر خود هستند که این می تواند به طریقی در توصیف داده ها مورد استفاده قرار بگیرد.

الگوریتم FastICA یکی از مشهورترین روشهای موجود در حل مسائل آنالیز مولفه های مستقل و جداسازی کورمنابع است. آزمایشات نشان داده شده است که کارایی و سرعت همگرایی این الگوریتم خیلی بیشتر از دیگر الگوریتمهای ICA است. در آزمایشی که فقط یکی از سطرهای ماتریس جداساز در نظر گرفته می شود، این الگوریتم همگرایی سریعی از خود نشان داد که این مورد را پردازش تک-واحد^۱ می نامند. در الگوریتم FastICA یک مرحله نرمال کردن بطور واضح وجود دارد. چرخش اضافی حاصل از نرمالیزاسیون در سرعت همگرایی اثر منفی دارد، اما به دلیل سرعت همگرایی زیاد FastICA اثر محسوسی بر همگرایی نمی گذارد. در یک مطالعه، مقایسه ای تجربی توسط [۲۰ و ۱۹] ارائه شده است که الگوریتم FastICA نسبت به روش ICA با استفاده از متد عمومی تندترین شیب، سرعت همگرایی بیشتری دارد. این قابل درک است، زیرا الگوریتم FastICA از نظر عملکرد مشابه تندترین شیب نیست و تقریباً می توان آن را یک روش نیوتون فرض کرد. به طورثوری این الگوریتم بسیار سریع همگرا می شود و آن را پردازش تک-واحد می نامند [۱۳]. در این الگوریتم فقط یکی از سطرهای ماتریس وزن در نظر گرفته می شود و متعامد بودن آن فقط به نرمالیزاسیون بردارهایی با طول واحد بعد از هر مرحله تکرار کاهش می یابد.

روشهایی دیگری برای تخمین ماتریس مخلوط در مدل ICA با $n > m$ بیان شده است [۲۱ و ۲۲ و ۲۳]. این موارد اغلب به نام مسائل بیشینه تعریف^۲ نامیده می شوند. مشکلی که همه روشهای بیان شده دارند این است که از لحاظ محاسباتی بسیار طاقت فرسا هستند. این مساله به طور اساسی به این علت است که مدل حل این مسائل، مدلی است که با داده های از دست رفته

¹ one-unit

² Over-complete