

OLAP چیزی نیست جز جدول جدولی که شاید قبلاً ۵۰ سال پیش توسط افرادی که ابداع شده و الان روی داده‌های بزرگ استفاده می‌شود و به عنوان یک روش خیلی توصیفی مهم از آن یاد می‌شود و خیلی چیز ساده‌ای است و چیزی که آسان توضیح

می‌دهیم. کاری که OLAP انجام می‌دهد در واقع خلاصه کردن داده‌ها یا Database مان روی جدول است، روی جدول چند بعدی، مسئله‌ها داریم، رسم جدول چند بعدی بر روی صفحه، کار راحتی نیست، تنها کاری که این روش انجام می‌دهد این است که

من آید، تغییر بیان را می‌توانیم به کمک چند قسمت و آنجا زاری می‌توانیم به کمک آنجا قسماً ما می‌توانیم این کار را انجام دهیم

### OLAP

● On-Line Analytical Processing (OLAP) was proposed by E. F. Codd, the father of the relational database.

این روش را clementin این روش

● Relational databases put data into tables, while OLAP uses a multidimensional array representation.

این روش به طولانی روی رسم این جدول دارد و خیلی حرفه‌ای روی این جدول کار می‌کند

- Such representations of data previously existed in statistics and other fields

مثلاً در آمار و آمارهای دیگر

● There are a number of data analysis and data exploration operations that are easier with such a data representation.

این روش در تحلیل و جستجو داده‌ها آسانتر است

این روش در تحلیل و جستجو داده‌ها آسانتر است! ما یک سری داده داریم که کسب می‌کنیم و آنجا زاری می‌توانیم به کمک آنجا قسماً ما می‌توانیم این کار را انجام دهیم

در واقع ما یک مربع داریم، با لایه‌های مختلف، و هر یک از این لایه‌ها یک مقدار است و این مقدارها را می‌توانیم در یک جدول OLAP نمایش دهیم. این جدولها برای داده‌های مختلف استفاده می‌شوند. برای داده‌های مختلف هم می‌توانیم درست کنیم. Contingency table

### Creating a Multidimensional Array

● Two key steps in converting tabular data into a multidimensional array.

- First, identify which attributes are to be the dimensions and which attribute is to be the target attribute whose values appear as entries in the multidimensional array.

جدول OLAP را از جدولی تبدیل می‌کنیم و بریم جدولی OLAP واقعا برای دو بعدی هم نیست خیلی

- ◆ The attributes used as dimensions must have discrete values
- ◆ The target value is typically a count or continuous value, e.g., the cost of an item
- ◆ Can have no target variable at all except the count of objects that have the same set of attribute values

۲م با لایه‌ها یعنی ما یک داده داریم، آن داده‌ها هم که می‌توانیم

- Second, find the value of each entry in the multidimensional array by summing the values (of the target attribute) or count of all objects that have the attribute values corresponding to that entry.

ممكن است چندتا هم بشود، چند تا تغییر می‌دهیم

عبارتاً در حالت ۳ بعدی ما می‌توانیم این را به صورت فکری رسم کنیم و روش‌های جدیدی هم در سال‌های اخیر توسط نرم‌افزارها ابداع شده برای نمایش دادن این جدولها، و ما می‌توانیم چون در نرم‌افزارها رواج پیدا نکرده، ما خیلی خودمان هم با این نمودارهای ۳ بعدی کار می‌کنیم.

پس برای اینکه ما یک Multi dimensional Array را درست کنیم، یک آرایه چند بعدی درست کنیم ما یک جدول چند بعدی درست کنیم، باید به چند نکته توجه کنیم، پس یک جدولی که نمودار چند بعدی مثل اینکه ما داده‌ها را درون یک آرایه سه بعدی، حالا ما می‌توانیم یک آرایه ۲ بعدی هم داشته باشیم که همگی آرایه چند بعدی می‌توانند. اولین کاری که ما باید انجام دهیم:

ابتدایین صفحا (Attributes) را مشخص کنید، پس ما باید مقصران را در مشخص کنیم چند مقصر داریم، هر  
 مقصران شامل چند بخش است میشود، در حال قبل در مقصران را در هر طرفان را در هر کد است به اینجین مقصر  
 مقصد: اعداد در جدول  
 اعداد که باید در جدول  
 بگذاریم، قبل سال قبل  
 ما قبل و بعد از این شماره  
 و فرانش های سال را در جدول  
 جدول بگذاریم، پس برای  
 این Multi Array  
 درست کنیم کارمان این  
 است. حال آنکه مقصر  
 داریم، مقصود از این  
 هر طرفان، مقصود از این  
 رابطنی، مقصود از این  
 کسای که ما این دارند به این  
 هر کد؟! ما این مقصود از این  
 مقصود از این مقصود از این  
 راه واقف این است که ما  
 باید مقصود از این در این  
 برای ما این دارد در جدول  
 بکنیم و برای ما این ندارد  
 در جدول و بعد از این  
 جدول به این  
 هست هر کد

WELDER QUALIFICATION MATRIX									
WR No	WELDER NAME	WPS No	MATERIALS	PROCESS	F Nos. Qualified	POS	THICKNESS QUALIFIED	DIA QUALIFIED	Issue, Revision, Date
W-9002	Talari Raju	OME_01	Carbon Steel - ASME IX	GTAW/SAW	All F No 6	6G	GTAW - 8mm max/ 14mm max	SMAW OD 25mm & above	Issue - 5 Revision - 0 Date - 20.07.2011
W-9003	Talari Raju	OME_06	CuNi - ASME IX	GTAW	F No 34 & All F No 41 through F No 46	6G	6.0 mm maximum	OD 73 mm & above	
W-9004	Santhosh Kumar P	OME_17	Carbon Steel Group I & II of AWS D1.1	FCAW	All F No 6	3G	3mm to Unlimited	24" OD & Above	
W-9005	Santhosh Kumar Y	OME_17	Carbon Steel Group I & II of AWS D1.1	FCAW	All F No 6	3G	3mm to Unlimited	24" OD & Above	
W-8005	Kanakaraju	GMS/MP/SMS-25	Carbon Steel Group I & II of AWS D1.1	SAW	F No 1 to 4	3G	5mm to Unlimited	24" OD & Above	
W-8007	Satheesh Kumar	OME_03	Carbon Steel Group I & II of AWS D1.1	SAW	F No 1 to 4	3G	5mm to Unlimited	24" OD & Above	
W-9006	Musharaf Ali	OME_16	Carbon Steel - ASME IX	FCAW	All F No 6	3G	Unlimited	24" OD & Above	
W-9007	Musharaf Ali	OME_16	Carbon Steel - ASME IX	FCAW	All F No 6	6G	Unlimited	27/8" OD & Above	
W-9008	Musharaf Ali	OME_17	Carbon Steel Group I & II of AWS D1.1	FCAW	All F No 6	6G	Unlimited	27/8" OD & Above	
W-9009	Murugan Rajendran	OME_16	Carbon Steel - ASME IX	FCAW	All F No 6	3G	Unlimited	24" OD & Above	
W-9009	Murugan Rajendran	OME_03	Carbon Steel Group I & II of AWS D1.1	SAW	F No 1 to 4	6G	22mm max	4" OD & Above	
W-9009	Murugan Rajendran	OME_01	Carbon Steel - ASME IX	SAW	F No 1 to 4	6G	16mm max	27/8" OD & Above	
W-9009	Murugan Rajendran	OME_17	Carbon Steel Group I & II of AWS D1.1	FCAW	All F No 6	3G	Unlimited	24" OD & Above	
W-9010	Reji George	OME_03	Carbon Steel Group I & II of AWS D1.1	SAW	F No 1 to 4	3G	5mm to Unlimited	24" OD & Above	
W-9011	Davidson Sair	OME_16	Carbon Steel - ASME IX	FCAW	All F No 6	3G	Unlimited	24" OD & Above	
W-9012	Habib Rahman	OME_16	Carbon Steel - ASME IX	FCAW	All F No 6	3G	Unlimited	24" OD & Above	
W-9013	Sivanesan Nadar	OME_05	Stainless Steel - ASME IX	GTAW	All F No 6	6G	11.0mm maximum	OD 25mm & above	
W-9017	Sivanesan Nadar	OME_05	CuNi - ASME IX	GTAW	F No 34 & All F No 41 through F No 46	6G	6.0 mm maximum	OD 73 mm & above	
W-9018	B Nageswara Rao	OME_07	Carbon Steel - ASME IX	GTAW/SAW	All F No 6 / All F 1 to F4	6G	GTAW - 12mm max/ SMAW - Unlimited	27/8" OD & Above	

Page 10 of 13



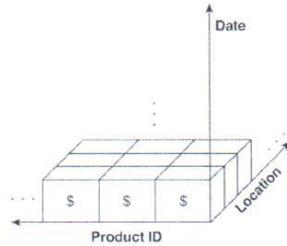


صیغه که البته ما فرار از بار است. Histodi حسابش میکنیم، بار است. contour plot، کانتورس را رسم میکنیم  
 نمودار سطح ترانس را رسم میکنیم تا به صورت ۳ بعدی perspective این را نشان می دهیم، البته نمودارهای ۲ بعدی هم داریم.

پس ما برای داده های ۲ بعدی بر اساس صیغه این کار را انجام دهیم.

### Data Cube Example مثال زره شده - مانند این شکل زیر است

- Consider a data set that records the sales of products at a number of company stores at various dates.
- This data can be represented as a 3 dimensional array
- There are 3 two-dimensional aggregates (3 choose 2), 3 one-dimensional aggregates, and 1 zero-dimensional aggregate (the overall total)



حسین برای این است. این برای راه های بیوس است، البته بیوس است اینی دیگر آن است اینی هم داریم.

### Data Cube Example (continued)

- The following figure table shows one of the two dimensional aggregates, along with two of the one-dimensional aggregates, and the overall total

	date				total
	Jan 1, 2004	Jan 2, 2004	...	Dec 31, 2004	
product ID 1	\$1,001	\$987	...	\$891	\$370,000
⋮	⋮	⋮	⋮	⋮	⋮
27	\$10,265	\$10,225	...	\$9,325	\$3,800,020
⋮	⋮	⋮	⋮	⋮	⋮
total	\$527,362	\$532,953	...	\$631,221	\$227,352,127



## OLAP Operations: Roll-up and Drill-down

- This hierarchical structure gives rise to the roll-up and drill-down operations.
  - For sales data, we can aggregate (roll up) the sales across all the dates in a month.
  - Conversely, given a view of the data where the time dimension is broken into months, we could split the monthly sales totals (drill down) into daily sales totals.
  - Likewise, we can drill down or roll up on the location or product ID attributes.

است، باید مدل می‌توانیم برایش برهم بر روی داده‌ها، ولی اگر 7 نفر شد، می‌توانیم 24000 نفر را از جدول کنیم  
در مورد جدول 7 نفری، وقتی وقتی به بالا می‌رویم تعداد افراد می‌تواند کمتر شود، اینها را در همان  
جست‌وجوی می‌توانیم در جدول جست‌وجوی کنیم.

در حیطه مدل در مورد خوشه بندی صعب بودیم، گفتیم clustering یا بدون نظارت است که هدفش قرار دادن داده های همگون توی یک خوشه است. با قدرش شرح کردیم، گفتیم که در صورتی که ما فاصله ها را از هم حساب کنیم، مثل صفتی های که در اسلام های درس بودیم، ما می آیم باید قدر فاصله آنها را اندازه گیری کنیم، اگر داده ها ایمان بدی بودند، این قدر ما خیلی ساده بود. همان قدر معمولی، فاصله ی بین دو نقطه را چگونه حساب می کردیم؟! از هم کم شان می کردیم، بدون آنکه بدانیم بعد خبرش می شد و می گفتیم این فاصله ی دو نقطه شده. ولی وقتی برداری بودند، یعنی نقطه ما از یک بعدی تر است که بعد از آن داده های ما این چنین هستند، گفتیم با بر بیاییم بگویم و این کار را انجام دهیم، یعنی مؤلفه های  $n$  دو نقطه را از هم کم کنیم و توان ۲ برسانیم + مؤلفه های  $n$  هم همین کار را در مؤلفه  $n$  یا  $n$  و این آخر هم داشته باشد، همین کار را برای تمام هم انجام دهیم و بعد می توانیم آبرسانیم و بعد با هم جمع شان کنیم و در نهایت خبرش بگیریم، این برای  $p$  بعدی است، بین فاصله ی دو نقطه جدولی که هر کدام  $p$  بعد دارند، این جور حساب می شود، این فاصله اولی است. اگر ما  $norm\ minkusky$  خواستیم انجام بدهیم،  $minkusky$  یا  $l_1$  یا  $l_2$  (یعنی ۱ و ۲ فاصله) داریم خبر هم نمی خواست بگیریم، بعد می گفتیم با استفاده از این ابزارها می توانیم کارهای خیلی خوبی هم انجام می دهیم، البته بعد صفرهای (بسیار تعریف کردیم، که انواع و اقسام قدرها را گفتیم، برای  $n$  قدر اولی تر از ما  $n$  نقطه  $p$  بعدی داشته باشیم، می توانیم فاصله ها را حساب کنیم البته در قالب یا نرم افزار  $clémentin$  این کارها را می توانیم انجام بدهیم و چون فقط باید از این مابین که قبلاً  $n$  تا عضو دارد، این مابین را گزارش کنیم، به صورت برداری ما این کارها می دهیم یعنی بر داریم فاصله ها به ماتریس  $n$  می رده نرم افزار ما مابین فاصله ها، می توانیم با تبدیل این بردار را به ماتریس تبدیل کنیم، این کار صحت نیست. مابین فاصله ها  $n$  می رده ای مان می خورد؟! و در صورتی که خوشه بندی کنیم، این خوشه بندی ما اگر جمع شوند باشد، یعنی بیاییم داده ها (صفت 474 صفت) ۰۰۰۰۰۰

clustering با استفاده از روش های سلسله مراتبی انجام بدهیم، آراه عمده داریم ۱ - بیاییم تمام داده ها را به صورت جدا جدا خوشه در نظر بگیریم یعنی به اندازه داده ها خوشه تبدیل کنیم بعد سعی کنیم با  $Merg$  کردن این داده ها، نهایتاً به یک خوشه برسیم، با این می کنیم روش جمع کردن یا اینکه برعکس هم داده ها را یک خوشه بگیریم و بعد سعی کنیم داده ها را از هم جدا کنیم، این روش می تواند روش تقسیم کننده یا (division) بین در درگاه سلسله مراتبی است که روش ما supervised نیست، ما فید این چیزها خوشه با بر داده های ما تبدیل شود، ما اطلاعاتی نداریم چطور همین می آیم تمام حالتها را در نظر بگیریم و بعد سعی می کنیم با استفاده از یک روش بهترین خوشه را جدا کنیم، ولی این کار را باید انجام دهیم یعنی تمام داده ها به اندازه تمام داده ها  $n$  داده داریم که  $n$  خوشه، نهایتاً ما می توانیم یک خوشه، یا یک خوشه داریم، هر چه  $n$  خوشه و نهایتاً جا می آید که می آید اینها را از هم تفکیک کنیم.

کرد و مشخص داد که کجا بهترین خوشه را می‌دهد. مشخص کنیم؛ ظاهره ~~و~~ بخش ~~میلون~~ clustering. اگر بعد از خوشه‌ها  
 نوی، در یک مرحله ما می‌توانیم مشخص باشد، ~~دیده~~  $\text{segmentation}$ ، یعنی یک ضرب ~~فامی~~ ~~آسم~~ ~~سرایخ~~ ~~خجاری~~ ~~به~~ ~~باید~~ ~~بارگی~~،  
 یک ضرب ~~۲۰~~، مرحله اول می‌آید، برای روش تقسیم ~~شونده~~ ~~۱۰~~ ~~داره~~ ~~عبارت~~ ~~میکند~~ ~~یک~~ ~~خوشه~~، بعد یک خوشه را تقسیم می‌کنیم به اول  
 دو خوشه، بعد ۳ خوشه، بعد ۴ خوشه و نهایتاً  $n$  خوشه که تعداد داده‌ها همان است. معاسبات باید برای همین  
 داده‌ها، انجام شود (این روش پارسیست نسبت و تفاوت است) این کار را که انجام می‌دهیم، در مرحله اول تقسیم می‌کنیم،  
 معاسبات و حساب می‌داریم چون در هر مرحله باید فاصله‌های همین داده‌ها را از هم ~~بسیار~~ ~~حساب~~ ~~کنیم~~، نوی مرحله اول تقسیم می  
 کنیم فاصله‌های داده‌ها را از هم ~~بسیار~~ ~~حساب~~ ~~می~~ ~~کنیم~~، فاصله تفاوت از هم ~~بسیار~~ ~~فرق~~ ~~نند~~ ~~روش~~ ~~مان~~ ~~جمع~~ ~~شونده~~ ~~باشد~~، اگر روش  
~~مان~~ ~~جمع~~ ~~شونده~~ ~~باشد~~ ~~کنیم~~ ~~هر~~ ~~یک~~ ~~از~~ ~~داده~~ ~~ها~~ ~~را~~ ~~باید~~ ~~خوشه~~ ~~در~~ ~~نظر~~ ~~می~~ ~~گیریم~~، پس این شد  $n$  تا خوشه، اینها هم در این  
 رابطه  $Merg$  کنیم، نوی هر مرحله یکی از تعداد خوشه‌ها را کم می‌شود، تا مرحله‌ای معاسبات این روش ختمی می‌کنیم است.  
 نوی مرحله اول می‌آید، داده‌ها را فاصله‌های رابطه حساب می‌کنیم، نوی ما ~~۱۰~~ ~~تاه~~ ~~میکنیم~~، آن در داده‌ها ~~این~~ ~~که~~  
 از هم ~~بسیار~~ ~~فاصله~~ ~~کمتر~~ است را  $Merg$  می‌کنیم، ~~میان~~ ~~یک~~ ~~خوشه~~، در مرحله بعد منخواهیم ~~بیا~~ ~~یم~~ ~~یک~~ ~~خوشه~~  
 داریم که در آن عضو دارد، یعنی خوشه‌ها را ~~باید~~ ~~عضو~~ ~~دارند~~، منخواهیم فاصله اینها را حساب کنیم، ما تا الان بلد بودیم فاصله  
 نقاط را حساب کنیم، فاصله نقطه از مجموع ~~را~~ ~~بلدیست~~ ~~حساب~~ ~~کنیم~~، پس نیاز به یک تعریف جدید داریم، معنی فاصله ~~یک~~ ~~نقطه~~  
 از مجموع ~~را~~ ~~بسیار~~ ~~تقریب~~  $uniak$  اینی نداریم، معنی تقریب داریم، بی از تفاوت، تقریب این است که فاصله ~~یک~~ ~~نقطه~~  
 از خوشه را ما تقریب کنیم؛ کمترین فاصله ~~ی~~ ~~نقطه~~ ~~تا~~ ~~اعضای~~ ~~آن~~ ~~خوشه~~، یعنی ~~بیا~~ ~~یم~~ ~~حاصل~~ ~~شود~~ ~~تاک~~ ~~ا~~ ~~معنای~~ ~~به~~ ~~سرو~~ ~~از~~  
 خوشه ~~حقیقت~~ ~~را~~ ~~با~~ ~~داخل~~ ~~خوشه~~ ~~ما~~ ~~حساب~~ ~~کنیم~~، اگر ~~ببینیم~~ ~~شان~~ ~~را~~ ~~بگیریم~~، این را به عنوان فاصله تقریب می‌کنیم، پس  
 فاصله ~~در~~ ~~ما~~ ~~مجموعه~~ ~~را~~، ~~با~~ ~~یک~~ ~~نقطه~~ ~~از~~ ~~یک~~ ~~مجموعه~~ ~~را~~، تقریب می‌کنیم؛ فاصله ~~تاک~~ ~~فاصله~~ ~~شان~~ ~~را~~ ~~اولی~~ ~~می~~ ~~بینیم~~ ~~شان~~ ~~را~~ ~~به~~ ~~عنوان~~  
 فاصله ~~هر~~ ~~یک~~ ~~مجموعه~~ ~~یک~~ ~~معنی~~ ~~معاسبات~~ ~~میلون~~ ~~ها~~ ~~اینجا~~ ~~داریم~~ ~~تاک~~ ~~۱۰~~ ~~اعضای~~ ~~که~~ ~~در~~ ~~ما~~ ~~حقیقت~~ ~~در~~ ~~۱۰~~ ~~های~~ ~~که~~ ~~در~~  
~~ن~~ ~~حقیقت~~ ~~۱۰~~ ~~داده~~ ~~مجموعه~~ ~~است~~، در آن خوشه است، ~~۱۰~~ ~~داده~~ ~~در~~ ~~مجموعه~~ ~~دوم~~، تا فاصله ~~عضو~~ ~~بسیار~~ ~~ندارد~~، پس ~~کل~~ ~~آن~~ ~~فاصله~~ ~~عضو~~  
~~را~~ ~~با~~ ~~تمام~~ ~~فاصله~~ ~~های~~ ~~اعضای~~ ~~۱۰~~ ~~حساب~~ ~~میکنیم~~، معنی این را می‌گیریم، کمترین قدری ~~که~~ ~~است~~ ~~آدم~~ ~~منوال~~ ~~فاصله~~  
 می‌داریم، ~~این~~ ~~فاصله~~  $minimum\ Distance$ ، به روش ~~مان~~ ~~میکند~~  $single\ linkage$ ، پس ما روش ~~های~~  
~~مختلفی~~ ~~داریم~~، برابر ~~این~~ ~~فاصله~~ ~~را~~ ~~چون~~ ~~تقریب~~ ~~کنیم~~، اسم روش ~~مان~~ ~~عوض~~ ~~من~~ ~~شود~~، ~~پس~~ ~~neighbor~~ ~~nearest~~  
 $single\ linkage$  در این روش ~~بی~~ ~~است~~، به روشی ~~می~~ ~~بینیم~~ ~~فاصله~~ ~~ی~~ ~~فاصله~~، نوی ~~داده~~ ~~مجموعه~~ ~~را~~ ~~حساب~~ ~~میکنیم~~ ~~به~~ ~~عنوان~~  
 فاصله تقریب می‌کنیم. (صفحه 477 کتاب مثال خواننده شود)



در k-means گذاشتیم که با جواب average linkage یکی جواب را برگزیند و در حالت کلی یکی نیستند.

حالا حساب می‌کنیم که ما در اینجا داریم (average linkage) که حسابات و حساساتی است، بخاطر همین بعضی جاها این روش هم آینه‌ها Centroid استفاده می‌کنند که در این روش به جای این میانگین فواصل نزدیک شود، فاصله میانگین‌ها را می‌گیرند. این در واقع کاملاً معکوس است.  $\bullet$  پس در Centroid داده‌ها را Component wise میانگین حساب

می‌کنیم، می‌داریم در یک بردار، سپس می‌داریم  $\bar{y}_A$  (مثلاً  $p$  تا نقطه داده) بعد میانگین تمام فواصل که می‌گیریم می‌گیریم  $A$  قرار می‌گیرند، فوگن اولشان را با هم جمع می‌کنیم، جنبش بر تعدادشان می‌کنیم، تعدادها  $h$  است، پس ما  $p$  دفعه میانگین می‌گیریم

اسمی می‌توانیم  $(\bar{y}_A)$  (صفحه 43 کتاب) و برای  $\bar{y}_B$  هم  $p$  میانگین می‌گیریم از  $n^2$  تا داده، مثلاً بیایم

$n_1$  تا داده داریم برای  $B$   $n_2$  تا داده داریم و حالا می‌توانیم فاصله میانگین‌ها را حساب می‌کنیم که از روش قبل حسابات

فصلی نسبت تراست، که فرمول‌ها به این صورت هستند:

$$D(A, B) = d(\bar{y}_A, \bar{y}_B)$$

$$\bar{y}_{AB} = \frac{n_A \bar{y}_A + n_B \bar{y}_B}{n_A + n_B} \quad \text{و} \quad \bar{y}_A = \sum_{i=1}^{n_A} \frac{y_i}{n_A}$$

دقت کنید که ما در این نسبت تراست که میانگین ما میانگین وزنی است، وقتی از خواسته میانگین  $A$  و  $B$  را حساب کنید این نزدیک میانگین را از اول بگیرد چون میانگین یک میانگین وزنی است، ما بیایم تعداد اعضاها را در میانگین ضرب کنیم، بخواهیم تعداد اعضاها را در میانگین جنبش بر تعداد کل این می‌کنیم، این بردار جدید به راست می‌آورد ~~...~~ میانگین جدیدی داشتیم که این است که نسبت، داده‌های پرت حساس است <sup>فصلی در کتاب</sup>، جای این میانگین با هم استوار می‌کنیم

خاطرات بدی این از میانگین استفاده کنیم. در صفحه 486 مقصود از  $\bar{y}_A$  و  $\bar{y}_B$  میانگین است نه میانگین.

Ward's Method چیست؟ در این مقادیر  $SSE$  تعریف کرده،  $SSEA$  و ما در اینجا می‌خواهیم حساب کنیم،

واریانس یعنی هراندگی داده‌ها حول میانگین، فرمول واریانس را هم بلدیم ~~...~~ مثلاً

$$S_2 = \frac{1}{(n-1) \sum (x_i - \bar{x})^2}$$

این برای وقتی است که داده‌ها را اسکنار می‌کنیم، اگر داده‌های ما برداری باشند، خط می‌کشیم  $(x_i - \bar{x})$  و  $(y_i - \bar{y})$  ضرب می‌کنیم، کاری که اینجا هم انجام داده همین است. (ص 486) این آنگاه می‌خواهیم واریانس تمام داده‌ها را حساب کنیم،

با هم می‌زنیم آن مجموعه را، آن بردار را معما می‌کنیم که این میانگین  $\bar{y}_A$  میانگین مؤلفه به مؤلفه است، پس  $SSEA$  در

$SSE_A$  و  $SSE_B$  را به همین صورت بدست می‌آوریم، حالا ما می‌توانیم  $SSE_{AB}$  را هم تعریف کنیم، یعنی در اینجا اولی  $SSE$

واریانس درون کلاس هستند، آن تقسیم بر تعداد آن می‌کنیم  $\bar{y}_A$  واریانس  $SSE_B$  یعنی می‌توانیم خط‌های مجموعه‌های  $B$ ،

این ما در اینجا داخلی که است، حالا می‌توانیم  $SSE_{AB}$  را بدست بیاوریم، یعنی بین  $A$  و  $B$  و  $A$  و  $B$  هر دو را هم اختلاف می‌دهیم

$$SSE_A = \sum_{i=1}^{n_A} (y_i - \bar{y}_A)' (y_i - \bar{y}_A)$$

$$SSE_B = \sum_{i=1}^{n_B} (y_i - \bar{y}_B)' (y_i - \bar{y}_B)$$

$$SSE_{AB} = \sum_{i=1}^{n_{AB}} (y_i - \bar{y}_{AB})' (y_i - \bar{y}_{AB}) \xrightarrow{\text{Transpose}}$$

میانگین گیری

$$\bar{y}_{AB} = \frac{n_A \bar{y}_A + n_B \bar{y}_B}{n_A + n_B} \quad , \quad n_{AB} = n_A + n_B \leftarrow \text{مجموع اعضای } B, A$$

روش Ward's method میگوید مقدماتی در آن است که با هم Merge کنیم، اگر SS بین دو کلاس کم باشد (بین آن

کم باشد) این عبارتی برای  $\bar{I}_{AB}$ ، مقیم ما  $\bar{I}_{AB}$  را نگاه میکنیم، این را با این بین  $A$ ،  $B$  است، خطای بین  $A$ ،  $B$

$$\bar{I}_{AB} = SSE_{AB} - (SSE_A + SSE_B) \text{ خطای } B \text{ + خطای } A$$

آر  $\bar{I}_{AB}$  کوچکتر شد یعنی این دو تا  $(A, B)$  با هم Merge شوند، با این روش میتوانیم همین کار را انجام دهیم و این دیزرتیشن

میگردد.  $\bar{I}_{AB}$  را سوالی کرده کردیم این را جدا رسیده که البته در اینجا این را جدا رسیده و کم نیستند و طبعی خواهد بود اما در

میزان شده است. میگویند که داده فرمول شده است در همین 488 دهم اثبات است، البته آن به شدت

کم درست است این روش قطعات است، در واقع همین روش centroid و این است که از square error loss

مترادف است استفاده کنیم.