شناسایی آماری الگو
بخش دوازدهم
(۴۱-۱۰-۷۱۱-۰۱)

ارزیابی روش‌های دسته‌بندی

دانشگاه شهید بهشتی

پژوهشکده‌ی فضای مجازی

بهار ۱۳۹۶

احمد محمودی ازناوه

فهرست مطالب

- شیوه‌های مختلف ارزیابی دسته‌بند
- روش‌های تقسیم مجموعه‌ی داده‌ها
- کارایی
- معیارهای ارزیابی

پیش‌گفتار

- با توجه به الگوریتم‌های دسته‌بندی مختلف و تأثیر هایپرپارامترها بر روی عملکرد یک روش دسته‌بندی مقایسه و انتخاب بهترین الگوریتم اجتناب‌ناپذیر است.

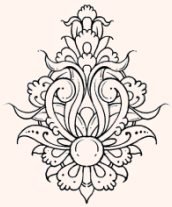

ارزیابی کارایی

- بررسی نتیجه‌ی دسته‌بند بر روی داده‌های آموزشی پذیرفتنی نیست، بلکه باید قدرت تعمیم‌پذیری روش را مورد ارزیابی قرار داد.
- معیار کارایی یک الگوریتم، خطای دسته‌بندی بر روی داده‌های آزمون(test) است.
  - داده‌هایی که در مرحله‌ی آموزش مورد استفاده قرار نگرفته‌اند.
  - حتی با جدا کردن داده‌های آموزش و آزمون یک بار بررسی کفایت نمی‌کند.
    - ممکن است مجموعه‌ی داده‌ها کم بوده و دارای داده‌هایی خاص(نویز و داده‌های برون‌هشته) باشند که بر نتیجه‌ی کلی اثر گذار هستند.
    - الگوریتم آموزش به مقادیر اولیه وابسته باشد.

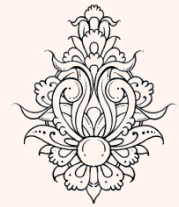

ارزیابی کارایی

- برای ایجاد یک دسته‌بند، یک الگوریتم دسته‌بندی و یک مجموعه داده‌ی آموزشی مورد استفاده قرار می‌گیرد.
- برای کاهش اثر عوامل تصادفی(داده‌های آموزشی، وزن‌های اولیه) یک الگوریتم برای ایجاد دسته‌بندهای متفاوت استفاده می‌شود.
- ارزیابی‌ها بر اساس توزیع خطا دسته‌بندهای متفاوت صورت می‌پذیرد.

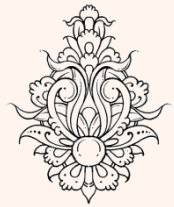

ارزیابی کارایی(ادامه...)

- باید توجه داشت که اعتبار این ارزیابی محدود به مجموعه داده‌ی مورد استفاده و کاربرد می‌شود و به معنای مقایسه‌ی کلی نمی‌باشد.

No Free Lunch Theorem

- هیچ الگوریتم بهینه‌ای برای تمام حالات وجود ندارد.
- معمولا داده به سه قسمت تقسیم می‌شود.
  - یک قسمت برای آزمون
  - دو قسمت برای آموزش و اعتبارسنجی
    - شبکه‌عصبی: داده‌آموزشی برای تنظیم وزن‌ها، داده‌های اعتبارسنجی برای تنظیم واحدهای مخفی و نرخ یادگیری و داده‌های آزمون برای ارزیابی نهایی
    - Knn: برای تنظیم k از داده‌های اعتبارسنجی استفاده می‌شود.

Cross Validation

- در تقسیم داده‌ها به دو قسمت باید توجه داشت که توزیع داده‌ها حفظ شود، بدین ترتیب دانش پیشین در مورد یک کلاس دستخوش تغییر نخواهد شد.

stratification

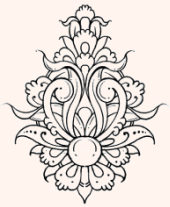

K-fold cross validation

- در این شیوه مجموعه‌ی داده‌ها به k قسمت مساوی تقسیم می‌شود. هر بار یک قسمت برای اعتبارسنجی و مابقی به عنوان مجموعه‌ی آموزشی به کار می‌رود.

$$\mathcal{V}_1 = \mathcal{X}_1 \quad \mathcal{T}_1 = \mathcal{X}_2 \cup \mathcal{X}_3 \cup \cdots \cup \mathcal{X}_K$$
$$\mathcal{V}_2 = \mathcal{X}_2 \quad \mathcal{T}_2 = \mathcal{X}_1 \cup \mathcal{X}_3 \cup \cdots \cup \mathcal{X}_K$$
$$\vdots$$
$$\mathcal{V}_K = \mathcal{X}_K \quad \mathcal{T}_K = \mathcal{X}_1 \cup \mathcal{X}_2 \cup \cdots \cup \mathcal{X}_{K-1}$$

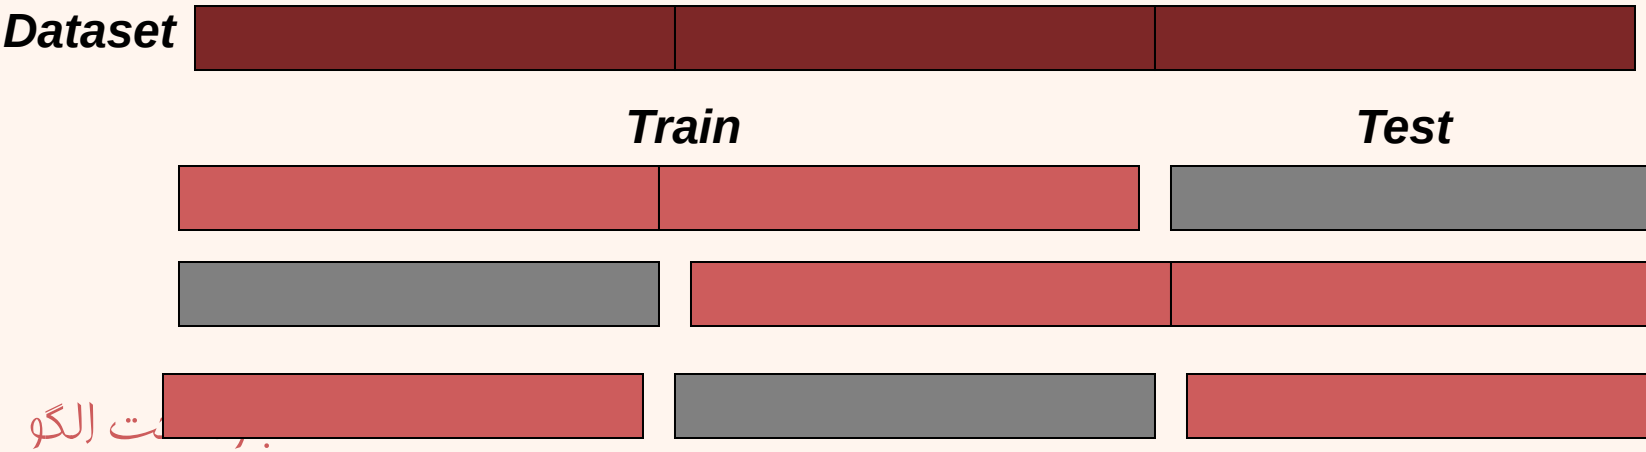

Leave-one-out (N-fold cross validation)

- یک حالت خاص k-fold است (k=N).
- این شیوه معمولا در مواردی مورد استفاده قرار می‌گیرد که تهیه‌ی داده‌ی برچسب خورده دشوار باشد. مانند تشخیص‌های پزشکی

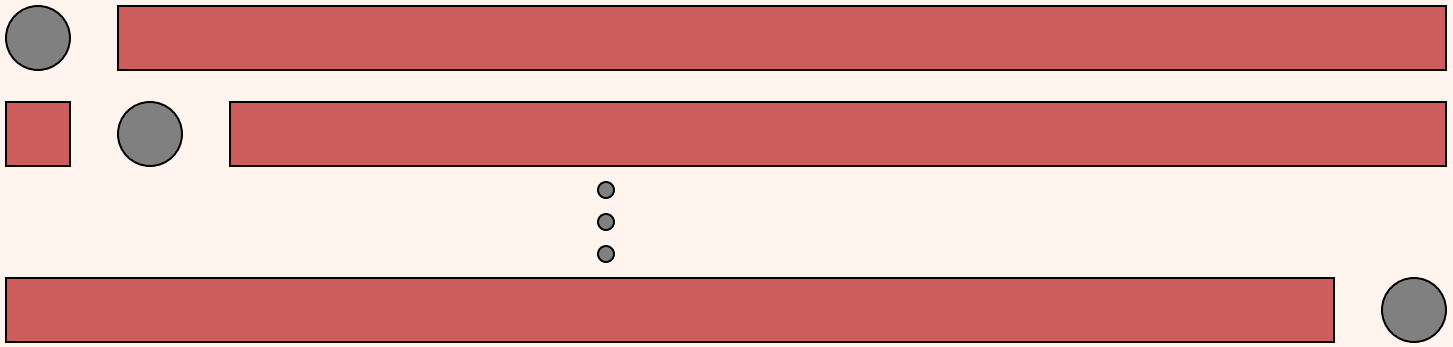

5×2 Cross-Validation

$$\mathcal{T}_1 = \mathcal{X}_1^{(1)} \quad \mathcal{V}_1 = \mathcal{X}_1^{(2)}$$
$$\mathcal{T}_2 = \mathcal{X}_1^{(2)} \quad \mathcal{V}_2 = \mathcal{X}_1^{(1)}$$

$$\mathcal{T}_3 = \mathcal{X}_2^{(1)} \quad \mathcal{V}_3 = \mathcal{X}_2^{(2)}$$
$$\mathcal{T}_4 = \mathcal{X}_2^{(2)} \quad \mathcal{V}_4 = \mathcal{X}_2^{(1)}$$

$$\vdots$$

$$\mathcal{T}_9 = \mathcal{X}_5^{(1)} \quad \mathcal{V}_9 = \mathcal{X}_5^{(2)}$$
$$\mathcal{T}_{10} = \mathcal{X}_5^{(2)} \quad \mathcal{V}_{10} = \mathcal{X}_5^{(1)}$$

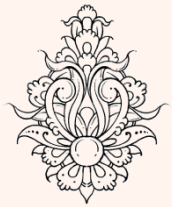

5 times 2 fold cross-validation (Dietterich, 1998)

Bootstrapping

- در این شیوه N نمونه با جایگذاری انتخاب می‌شود.
- احتمال انتخاب یک نمونه 1/N است.
- احتمال این که یک نمونه N بار انتخاب نشود:

$$\left(1-\frac{1}{N}\right)^{N} \approx e^{-1} = 0.368$$

- در نتیجه می‌توان گفت هر بار مجموعه‌ی آموزشی تنها ۶۳ درصد داده‌ها را در بر می‌گیرد.

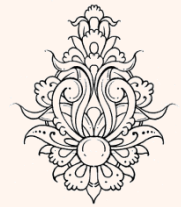

ارزیابی شیوه‌های مختلف دسته‌بندی

Performance

- **کارایی**:
  - پیش‌بینی درست برچسب کلاس

Time and Space complexity

- **پیچیدگی زمانی و مکانی**:
  - زمان (حافظه) مورد نیاز برای آموزش
  - زمان (حافظه) مورد نیاز برای دسته‌بندی

Robustness

- **مقاومت**:
  - مقاومت در برابر نویز(برچسب‌های اشتباه)، عدم وجود برخی مؤلفه‌ها

Interpretability

- **تفسیرپذیری**:
  - امکان استخراج دانش
- معیارهای دیگری نظیر ریسک دسته‌بندی و سادگی نیز دارای اهمیت می‌باشند.

معیارهای ارزیابی

Confusion Matrix

- ماتریس درهم‌ریختگی(CM): در این ماتریس مؤلفه‌ی $CM_{i,j}$ بیانگر این است که چند عنصر از کلاس نام به عنوان عضوی از دسته‌ی j برچسب خورده است.

	Ball	Car	Dri	Feed	Left	right	Pet	Shake	Sniff	Walk
Ball	4.93	0	0	0.03	0.01	0	0	1.08	0.77	0.18
Car	0	12.62	0.06	0.03	0.04	0	0.07	0	0.18	0
Drink	0	0.45	3.26	0.35	0.02	0.01	0.17	0	0.72	0.02
Feed	0.2	0.24	0.46	7.61	0.95	0.3	1.84	0.2	0.35	0.85
LookLeft	0.51	0.94	0	1.01	3.76	2.43	0.21	0.36	0.05	1.73
LookRight	0	1.04	0	0.33	0.72	4.66	0.38	0	0.43	1.44
Pet	0	0.57	0	0.65	0.17	0.03	11.47	0.01	0.1	0
Shake	0.09	0	0	0.08	0.01	0	0.23	8.59	0	0
Sniff	0.04	0.06	0.01	0.07	0.09	0.09	0.04	0	13.14	0.46
Walk	0.03	0	0.02	0.05	0.45	0.11	0	0	0.85	11.49

معیارهای ارزیابی(ادامه...)

- در دسته‌بندی دوکلاسی این ماتریس چهار عنصر دارد:
  - مثبت صحیح

True Positive

    - شخص بیمار، به درستی بیمار تشخیص داده شود.
  - مثبت کاذب:

False Positive

    - شخص سالم، به اشتباه بیمار تشخیص داده شود.

True Negative

  - منفی صحیح
    - شخص سالم، به درستی سالم تشخیص داده شود.

False Negative

  - منفی کاذب
    - شخص بیمار، به اشتباه سالم تشخیص داده شود.

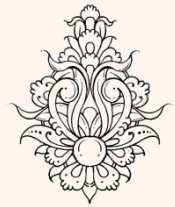

معیارهای ارزیابی(ادامه...)

Actual Class	Predicted Class: True	Predicted Class: False	
True	TP	FN	P
False	FP	TN	N

Error Type II

Error Type I

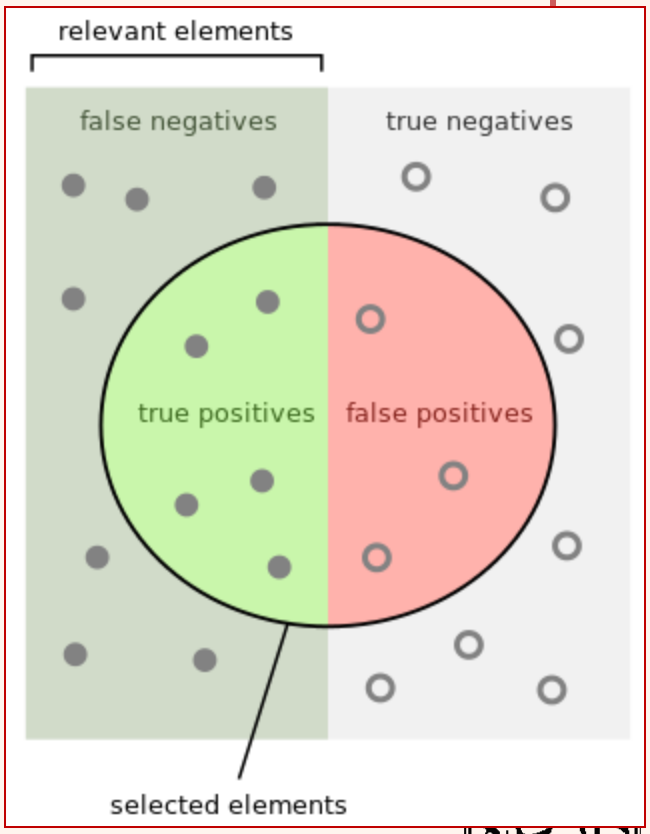

معیارهای ارزیابی(ادامه...)

- درستی(accuracy): نسبت نمونه‌های که برچسب درست خورده‌اند به کل نمونه‌ها

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} = \frac{TP + TN}{P + N}$$

- نرخ خطا(error rate):

$$error\_rate = 1 - accuaracy = \frac{FP + FN}{P + N}$$

- حساسیت(Sensitivity)، یادآوری(recall): **True Positive Rate(TPR)**

$$sensitivity = \frac{TP}{TP + FN} = \frac{TP}{P}$$

- تشخیص(ویژگی)(specificity): **True Negative Rate(TNR)**

$$\text{specificity} = \frac{TN}{TN + FP} = \frac{TN}{N}$$

حساسیت به معنای احتمال درست تشخیص بیماری است
تشخیص به معنای احتمال درست تشخیص سالم بودن است

منحنی مشخصه عملکرد سیستم

Receiver Operating Characteristics (ROC)

- این منحنی رابطه‌ی بین TPR و FPR را نشان می‌دهد، زمانی که حدآستانه‌ی جداسازی تغییر می‌کند.

– در واقع این منحنی ابزاری است که می‌تواند برای انتخاب حدآستانه‌ی بهینه به کار رود.

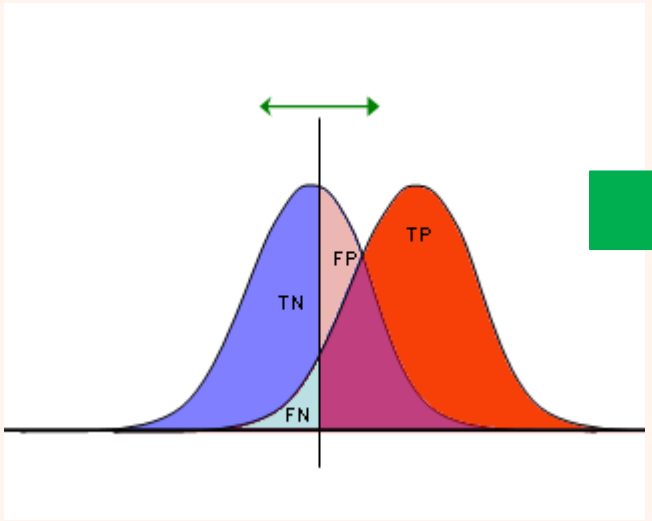

دسته‌بندی بهتر

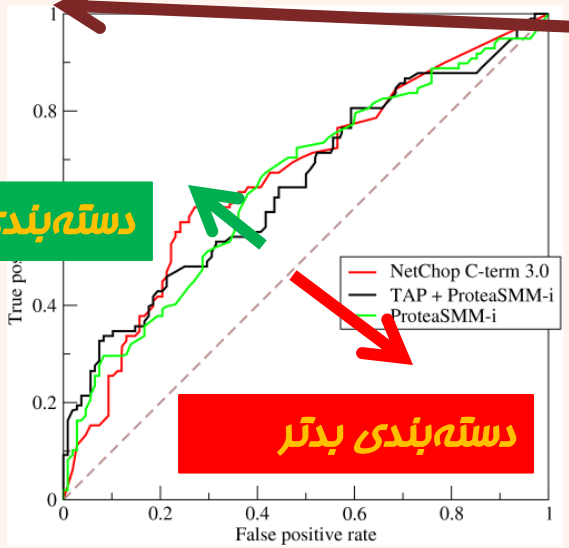

دسته‌بندی ایده‌آل

معیارهای ارزیابی(ادامه...)

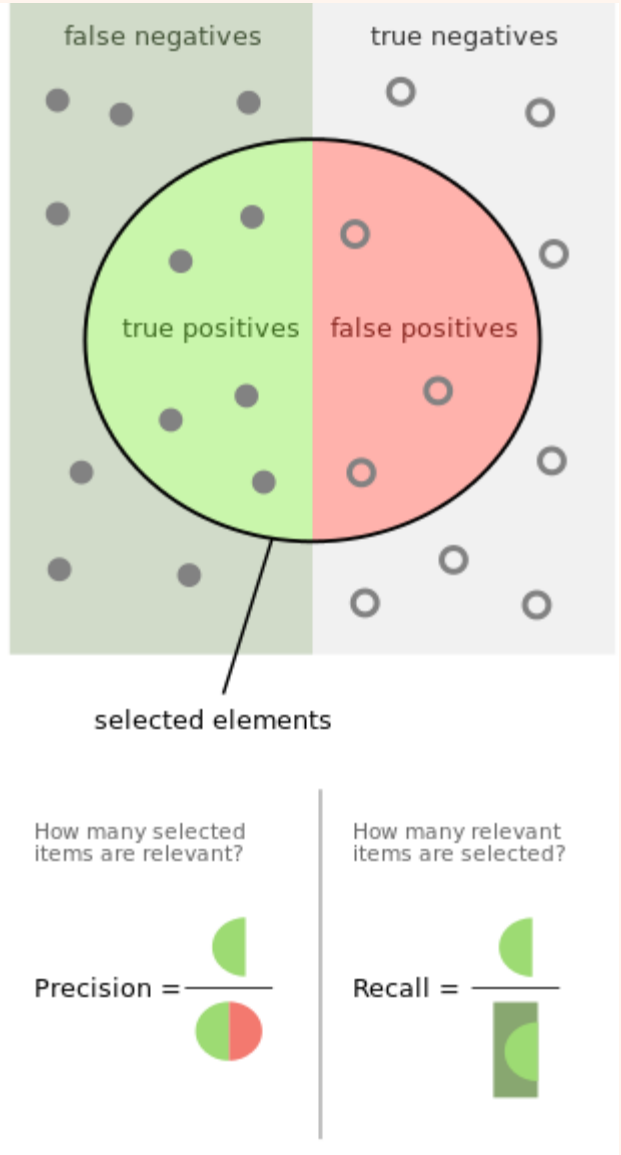

- یادآوری(recall):

$$recall = \frac{TP}{TP + FN} = \frac{TP}{P}$$

- دقت(precision):

$$precision = \frac{TP}{TP + FP}$$

- معیار F1(F_1 Score):

$$F_1 = \frac{2TP}{2TP + FP + FN}$$

معیار F_1 (F_1 Score):

- این معیار در واقع میانگین هارمونیک دقت و یادآوری است:
  - در بین میانگین‌های فیثاغورثی کم‌ترین مقدار را دارد.

$$F_1 = \frac{2\,precision \times recall}{precision + recall} = \frac{2}{\frac{1}{precision} + \frac{1}{recall}}$$

- با توجه به این با تغییر حد آستانه دو مقدار دقت و یادآوری تغییر می‌کنند، معمولا از این معیار برای مقایسه‌ی دسته‌بندها استفاده می‌شود.

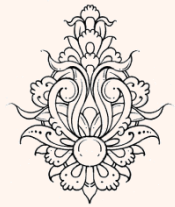

مثال

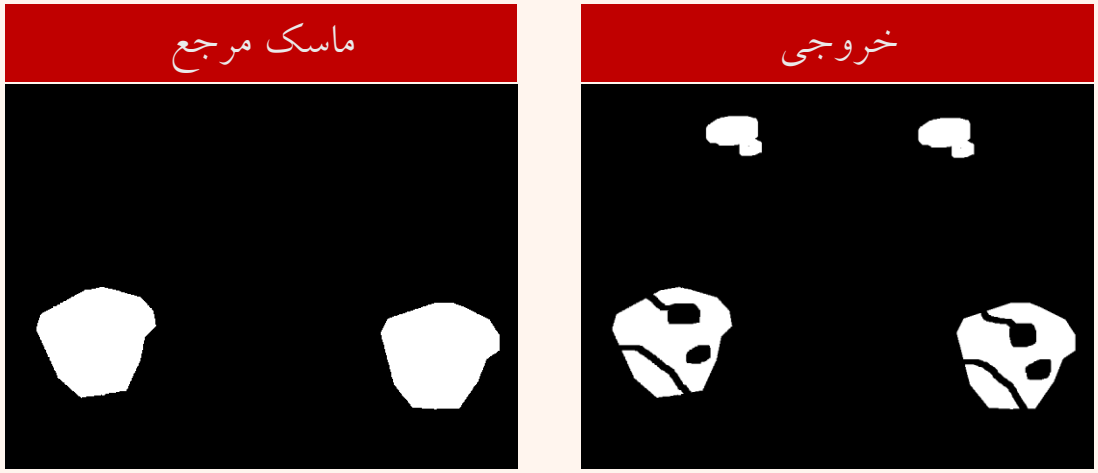

گزارش میانگین هر معیار

$$\text{Recall} = \frac{\left|\{\text{Forged Pixels}\} \cap \{\text{Detected Pixels}\}\right|}{\left|\{\text{Forged Pixels}\}\right|}$$

$$\text{Precision} = \frac{\left|\{\text{Forged Pixels}\} \cap \{\text{Detected Pixels}\}\right|}{\left|\{\text{Detected Pixels}\}\right|}$$

$$F_1 = 2\frac{\text{Recall} \times \text{Precision}}{\text{Recall} + \text{Precision}}$$