

視線運動の離散性を用いた視線認識

山畠利彦[†] 藤江真也^{††} 小林哲則[†]

[†] 早稲田大学 理工学部

^{††} 早稲田大学 理工学総合研究センター

〒 169-8555 東京都新宿区大久保 3-4-1

あらまし:

視線認識を目の部分画像を用いて行う際に、視線運動の離散性を利用して、複数フレームから得られる情報を統合することを試みる。単一の画像から得られる情報は、視線方向以外にも個人性や照明条件等の環境に関する情報を多く含んでいる。個人性や環境の画像に与える影響は大きく、数多くデータを収集して個人・環境非依存のモデルを作ると、曖昧性が大きく、良い性能が得られないことが知られている。一方、一つの対話セッションの間、対話相手や照明条件が急に変化することは極めて稀である。従って、同一対話内における複数フレームの画像を用いて得られる差分情報は個人性や環境の影響を受けにくいと考えられる。また、人の視線は瞬時的変化と安定を繰り返す傾向にある。本研究ではこの瞬時的変化を捉えて時間を分割し、単一画像・複数画像による情報を、状態遷移モデルを用いて逐次検証することで、対話全体に亘って最も尤もらしい視線方向の列を求めることを試みた。実際の対話データを用いて行った実験で、単一画像を用いた場合に0.66であったF値が、0.89まで向上した。

Gaze Recognition Using Discreteness of its Movement

Toshihiko YAMAHATA[†], Shinya FUJIE^{††}, Tetsunori KOBAYASHI[†]

[†]School of Science and Engineering, Waseda University

^{††}Advanced Research Institute for Science and Engineering, Waseda University

3-4-1 Okubo, Shinjuku-ku, Tokyo 169-8555, Japan

Abstract:

We've tried to improve gaze recognition accuracy by integrating information of image sequence and utilizing discreteness of gaze movement. Single image of eye region gives information about not only gaze direction but also individuality and environments, such as illumination conditions. Since such information, not essentially related to gaze direction, affects image strongly, the person environment independent gaze model which is trained with a lot of image including such information might not work so well because of its ambiguity. On the other hand, during one dialogue session, the dialogue partner never changes and it is quite rare that the environment changes rapidly. Thus, information given by difference between the frames should not be affected by individuality and environment. Moreover, human tends to repeat instantaneous change and brief fix of gaze direction. In this study, we capture these instantaneous change and confirm the information given by both single image and multiple images using state transition model to obtain the most likely sequence of gaze directions. In the experiment with actual dialogue data, our method achieved 0.89 of F-value while only single image achieved 0.66.

1 はじめに

目の画像パターンから視線認識を行う枠組みにおいて、単一の画像から得られる特徴量だけでなく、複数の画像の差分から得られる特徴量も組み合わせることで認識を行うことにより、認識精度の向上を目指す。

本研究では特に、音声対話システムと対話しているユーザの視線を認識することを目標とする。音声対話システムのプラットフォームとして対話ロボット(図1)を考える。対話において視線が担う役割

には様々なものがあるが、ロボットと人の対話において特に重要な役割を果たしているのは、相手がこちらを見ているか見ていないかの情報であると考えられる。例えば、人が一通りのことを喋り終わった時、人がロボットの方を見ていれば、その人は次にロボットが喋ることを期待していると考えられる。逆に、人がロボットでは無く別のところを見ていれば、人は続けて喋ろうとしていると考えられる。

画像情報を用いた視線認識の手法は、目の部分的




図 1: 対話ロボット「ROBISUKE」

な特徴（黒目の位置、形状、虹彩などの部品）を抽出して認識する手法 [4, 5, 6] と目の画像パターンから視線を認識する手法 [7, 8, 9, 10] の 2 つに大別される。前者の手法は認識に利用する画像の解像度が比較的高く、正確に部品を抽出できる場合において詳細な角度情報を得ることができる。しかし、人は対話中に頻繁に頭部動作を行うため、常に正確な部品抽出が行えることは期待できない。

本研究では、目の画像パターンから視線を認識する手法を用いる。目の画像パターンから視線を認識する手法としては、ニューラルネットワークを用いた手法 [7]、部分空間法を用いた手法 [8]、最近傍探索を用いた手法 [9]、SVD を用いた手法 [10] などが提案されている。これらの手法は目の部品を正確に抽出せずに、低解像度画像を用いて視線の認識を行っているが、個人性や環境に依存したモデルを用いている。目の部分画像は個人性や環境に関する情報も多く含んでいるため、それらに依存させたモデルにすることは妥当であると言える。一方で、応用に際しては個人性や環境に非依存なモデルを構築し、人物や環境を特定せずに認識できることが望まれる。しかしながら、個人性や環境に関する情報を含んだデータを大量に集めたところで、得られるモデルの視線方向に関する信頼性は高くない。

本研究では、以下の 2 点に着目する。1 点目は、人の視線の動きが離散的であることである。人の視線は連続的に変化するわけではなく、瞬時的変化と安定を繰り返す傾向にある。この瞬時的変化を捉え、この変化を超えた複数の画像から差分を計算することで、視線の変化に関する情報が得られる。2 点目は、対話中に個人や環境がほとんど変動しないことである。このことから、差分の計算時に個人や環境に関する情報はキャンセルされていることが期待できる。また、対話全体に対して認識結果を検証することで、対話全体として最も尤もらしい結果が得られる。

これらの仮説の下に、単一の画像から得られる情報、複数の画像から得られる差分情報を統合し、対話全体に対して検証を行うことで精度の高い視線認識を行うことを試みる。差分情報は個人や環境に関する情報がキャンセルされていることが期待できるものの、視線の絶対位置（正面を向いているか否か）に関する情報も同様にキャンセルされており、直接視線を認識することは難しいと考えられる。本研究では、状態遷移モデルを用いて、信頼性は低いながらも絶対的な視線方向が分かる単一画像から得られる情報と、相対的な変化しか捉えられないが信頼性の高い差分から得られる情報を統合する。

以下、2 で視線方向データについて述べ、3 で単一の画像による認識について述べる。4 では、差分の計算方法と、その妥当性の検証のために行った予備実験について述べる。5 では、本研究で用いた状態遷移モデル、それを用いた認識実験について述べ、6 でまとめる。



図 2: 識別対象の例

2 視線方向データ

2.1 識別対象

本研究では、ユーザが対話相手であるロボットに視線を向けているか向けていないかを識別することを目的とする。この目的を達成するために、考えられる最も単純な構成の識別器は、ユーザの視線が向けられている、ユーザの視線が向けられていない、という 2 カテゴリが設定されたものである。しかしながら、ユーザがロボットの方に視線を向けていない場合、視線をどこかに外していることになるが、その外し方は一通り（一方向）ではない。例えば、右上に外した場合と左下に外した場合とでは、その見た目が大きく異なることが予想される。そこで、視線が向けられていない場合の状態を、上下左右（斜めを含む）8 方向に分け、それに視線が向けられている状態を加えた計 9 カテゴリを設定した。識別対象の例を図 2 に示す。

2.2 データ収集

対話中に得られる画像を、人同士の対面対話から得るために、ハーフミラーを用いた撮影環境を利用した。この環境を利用することにより、ユーザ役がシステム役の人を見ている時に、カメラの方向を見ている映像が撮影可能となる。図 3 の最上部の画像が入力画像の例である。1 回の収録で、約 5 分収録し、16 人分のデータを収集した。それらのデータに対して、前節で設定されたカテゴリのタグ付けを行った。方向のタグはタグ付けした人の主観で決めており、厳密な境界はない（例えば、右と右上の境界など）。タグ付けの結果、1 人当たり、正面を見ているデータ約 6000 枚、各方向のデータそれぞれ約 200 枚程度収集できた。頭部の動きに関しては、大きくそむけることは禁止したが、固定はしていない。そのため、傾き等の動作は頻繁に観察された。

目領域の切り出しは、Active Appearance Models [2] から得られた目領域付近を初期値とし、目領域の平均画像をテンプレートとしてマッチングさせた。切り出された部分画像において、目の位置はほぼ同じになることが期待される。切り出された画像を濃淡正規化した後、サイズを 60×20 に拡大縮小した。1 フレームの画像からの切り出しの様子を図 3 に示す。

なお、普段眼鏡をかけている人は、眼鏡を外した上で収録を行った。

2.3 評価基準

本研究ではユーザが視線を向けているか向けていないかを識別することが目的であるという観点から、視線認識実験においては以下の評価値を用いた。

$$\begin{aligned}
 recall &= \frac{\text{正面のデータのうち正面と認識した数}}{\text{正面のデータ数}} \\
 precision &= \frac{\text{正面と認識した中での正解数}}{\text{正面と認識した数}} \\
 F &= \frac{recall + precision}{2}
 \end{aligned}$$




図 3: 目領域抽出の流れ

3 単一の画像による認識

以下、単一の画像から得られる特徴量を静的特徴量と呼ぶ。本節では静的特徴量のみを用いた認識について述べる。

3.1 識別手法

60×20 にサイズ変換された部分画像の画素値を横に並べた 1200 次元のベクトルを PCA で 90 次元 (累積寄与率約 90%) に次元圧縮した後、さらに LDA で 10 次元に次元圧縮したものを特徴量として用いた。識別は混合正規分布 (GMM) により行った。

3.2 静的特徴量による視線認識実験

3.1 の手法を用いて、視線認識実験を行った。2 で収集したデータのうち、学習データには評価データの被験者を含められないようにし、交差検定を行った。被験者別の評価値を表 1 に示す。

3.3 考察

表 1 から分かるように、recall が著しく低い。被験者別の誤り傾向を調べたところ、正面のデータがある特定の方向に誤認識されやすいということが分かった (その特定の方向は被験者により異なる)。

そこで、COSMOS 法 [11] を用いてモデル可視化を行った。COSMOS 法は、多次元パラメータを特徴量とするモデル (ここでは単一正規分布) を、可能な限りモデル間の距離を保ったまま次元圧縮することで、2 次元平面上へ写像する手法である。学習モデルと評価データで学習したモデルを写像した。同じカテゴリの学習モデルと評価データで学習したモデルが近くに写像されれば、認識に有利であると言える。写像した結果を図 4 に示す。(a) が F 値の高い被験者 C の場合、(b) が正面のデータがほとんど左下方向に認識されてしまう被験者 G の場合、(c) が正面のデータがほとんど左に認識されてしまう被験者 F の場合である。他の recall の低い被験者においても同様の傾向が見られた。写像の結果から、被験者のモデルが学習モデルからある方向にずれていて、その結果、recall が著しく低くなっていると考えられる。




図 4: COSMOS 法による視線方向モデルの分布図。各矢印はその方向を見ている状態、○はカメラを見ている状態のモデルをそれぞれ表す。黒地のものは学習データで作成したモデル、白地のものはテストデータで作成したモデルを表す。




図 5: 視線方向の状態遷移図

全ての状態間の状態遷移を考慮しているが、ここでは見やすさのため、近傍の状態への遷移のみ記述している。

4 差分画像による状態変化の推定

以下、2 枚の画像から得られる特徴量を動的特徴量と呼ぶ。本節では、動的特徴量による状態変化の推定について述べる。状態とは識別対象に設定した 9 つのカテゴリを指す。視線方向の状態遷移図を図 5 に示す。動的特徴量からどの程度状態変化を推定できるのか確認するために実験を行った。ここで、全てのフレーム間から動的特徴量の計算を行ってもほとんどのフレーム間において状態が変化しないと考えられる。また、瞬きの瞬間は状態の変化とは無関係の変化になってしまうことが予想される。そこで、画像の差分値のノルムを用いてフレームをセグメントに分割し、そのセグメント間から動的特徴量を計算し、状態変化の推定実験を行った。

4.1 セグメント分割

セグメント分割は以下の式を $\Theta = 2$ とし、5 フレームでの画像の差分値のノルムを閾値判定することにより行った。全てのデータに対してセグメント分割を行った結果、1 人当たり、正面を見ているセ

表 1: 静的特徴量のみを用いた時の被験者別の評価値

被験者 ID	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	平均
recall	0.03	0.36	0.87	0.61	0.51	0.29	0.13	0.87	0.33	0.01	0.35	0.32	0.04	0.76	0.47	0.86	0.43
precision	0.95	0.90	0.98	0.99	0.97	0.91	0.95	0.96	0.55	0.84	0.98	0.75	0.92	0.87	0.82	0.93	0.89
F	0.49	0.63	0.93	0.80	0.74	0.60	0.54	0.92	0.44	0.43	0.67	0.54	0.48	0.82	0.65	0.90	0.66




図 6: セグメント分割の例

グメント約 300 個, 各方向のセグメントそれぞれ約 13 個得られた. セグメント分割の例を図 6 に示す.

$$d_t = \left\| \frac{\sum_{\theta=1}^{\Theta} \theta \{I_{t+\theta} - I_{t-\theta}\}}{2 \sum_{\theta=1}^{\Theta} \theta^2} \right\| \quad (1)$$

4.2 動的特徴量による状態変化の推定実験

全通りの状態変化の計 81 カテゴリを識別カテゴリとした場合と状態の変化なしと 8 方向の相対的な変化の計 9 カテゴリを識別カテゴリとした場合の 2 つの実験を行った.

動的特徴量には, セグメントの中央フレーム同士の差分画像 60×20 を横に並べた 1200 次元のベクトルを PCA で 100 次元 (累積寄与率約 90%) に次元圧縮した後, それぞれの識別カテゴリの設定の上で LDA の変換行列を学習し, 10 次元に次元圧縮したものをを用いた. 識別は GMM により行った.

学習データには評価データの被験者を含めないようにし, 交差検定を行った.

4.2.1 全通りの変化を識別カテゴリとした場合

全通りの状態変化 (81 通り) を識別カテゴリとして実験を行った. 状態が変化しない場合 (正面 → 正面, 上 → 上, 右上 → 右上, 等) も含む.

81 通りの状態の変化を完全に認識できた割合はわずか 8.91% だった. 完全に認識とは, 例えば, 正面 → 上 という状態変化に対して, 正面 → 上 という認識結果ならば正解ということである. しかしながら, 差分を用いているので, 下 → 正面, 下 → 上, などといった相対的に上方向に変化している状態変化のモデルと似ていることが予想される. そこで, 相対的な変化が同じ状態変化と認識した場合でも正解とした場合の正解率を算出した. その場合, 正解率は 71.9% であった. また, 状態が変化しないデータが状態が変化しないカテゴリに認識されている割合は 80.6% であった.

ここで, 8 方向の相対的な変化の正解率の算出の際, 右上方向の変化のデータに対して, 右方向, 上方向といったように隣の方向に認識した場合も正解とした. これはタグ付けの曖昧性から許容できると考えられるからである.




図 7: 特徴量 1 次元で考えた時の例

4.2.2 状態の変化なしと 8 方向の相対的な変化を

識別カテゴリとした場合

4.2.1 の実験から, 状態の変化なしと 8 方向の相対的な変化で考えた場合, ある程度の認識はできると分かった. そこで, 識別カテゴリを状態の変化なしと 8 方向の相対的な変化の計 9 カテゴリとし, このカテゴリ設定のもとで, 再びモデルの学習を行った.

8 方向の相対的な変化の正解率は 76.8%, 状態の変化なしの正解率は 85.0% であった. どちらの正解率も全通りを識別カテゴリとした場合に比べ上昇した.

5 状態遷移モデルによる認識

3.3 の考察から特徴量空間における学習モデルと評価データで学習したモデルの分布は似ているが, シフトしていることにより, 認識精度の低下を導いているということが分かった. 特徴量 1 次元で考えた時の例を図 7 に示す. この例の場合, 静的特徴量のみを用いた場合, 正面のデータは上に, 下のデータは正面に誤認識される結果となる.

ここで, 相対的な変化を推定できることを利用することを考える. 時系列のデータに対して一定時間状態変化を観察し, 最も尤もらしい状態遷移を推定すれば, 正しい認識を行えると考えられる. 例の場合, 始めに上方向に変化し, 次に下方向に変化し, その後さらに下方向に変化している. その時, 時系列で考えると正面 → 上 → 正面 → 下 が最も尤もらしい状態遷移であると推定できると考えられる.

ここで, 信頼性は低い絶対的な視線方向が分かる単一画像から得られる情報と, 相対的な変化しか捉えられないが信頼性の高い差分から得られる情報を統合する枠組みとして, 状態遷移モデルを用いた.

5.1 本研究で用いた状態遷移モデル

本研究では,

1. 状態毎の静的特徴量の出力確率分布
2. ある状態からある状態への状態遷移時の動的特徴量の出力確率分布
3. 特徴量によらず一定の遷移確率分布

によって定義される状態遷移モデルを用いた. ビタビアルゴリズムにおけるスコアを式 (2) に示す.

表 2: 実験で用いた遷移確率

		遷移先								
		正面	上	右上	右	右下	下	左下	左	左上
遷 移 元	正面	0.6	0.05	0.05	0.05	0.05	0.05	0.05	0.05	0.05
	上	0.3	0.2	0.1	0.08	0.08	0.08	0.08	0.08	0.1
	右上	0.3	0.1	0.2	0.1	0.08	0.08	0.08	0.08	0.08
	右	0.3	0.08	0.1	0.2	0.1	0.08	0.08	0.08	0.08
	右下	0.3	0.08	0.08	0.1	0.2	0.1	0.08	0.08	0.08
	下	0.3	0.08	0.08	0.08	0.1	0.2	0.1	0.08	0.08
	左下	0.3	0.08	0.08	0.08	0.08	0.1	0.2	0.08	0.08
	左	0.3	0.08	0.08	0.08	0.08	0.08	0.1	0.2	0.1
	左上	0.3	0.1	0.08	0.08	0.08	0.08	0.08	0.1	0.2

$$\delta_t(j) = \alpha \log P_i(\mathbf{x}_t) + \max[\delta_{t-1}(i) + \beta \log P_{i,j}(\Delta \mathbf{x}_t) + \gamma \log a_{i,j}] \quad (2)$$

($\alpha + \beta + \gamma = 1$)

ここで、 $P_i(\mathbf{x}_t)$ が t 番目のセグメントにおける、状態 i の静的特徴量の出力確率分布、 $P_{i,j}(\Delta \mathbf{x}_t)$ が t 番目のセグメントにおける、状態 i から状態 j への状態遷移時の動的特徴量の出力確率分布、 $a_{i,j}$ が特徴量によらない遷移確率である。

5.2 状態遷移モデルを用いた視線認識実験

5.1 で述べた状態遷移モデルを用いて視線認識実験を行った。静的特徴量はセグメント内の特徴量の平均、静的特徴量の出力確率分布は 3.2 で学習したものを用いた。動的特徴量は 4.2.2 と同様に中央フレーム同士の差分画像から算出し、動的特徴量の出力確率分布も 4.2.2 において学習したものを用いた。そのため、相対的な変化の方向が同じ状態遷移には同じ出力確率分布が割り当てられる。遷移確率は全データから計算したものを手動で調整したものをを用いた。用いた遷移確率を表 2 に示す。

最終セグメントにバックトラックを行い結果を求めた。 α , β , γ は 0.1 ずつ変化させ評価した。 α , β , γ 毎の評価値を表 5 に示す。

また、静的特徴量のみを考慮したことに相当する $\alpha = 1.0$, $\beta = 0.0$, $\gamma = 0.0$ の時の被験者別の評価値を表 3 に、F 値が最も大きくなった $\alpha = 0.1$, $\beta = 0.5$, $\gamma = 0.4$ の時の被験者別の評価値を表 4 に示す。

5.3 考察

静的特徴量のみで認識を行った場合の recall 0.43 に比べて、状態遷移モデルを用いた認識は recall 0.93 と、著しく上昇した。実際、静的特徴量のみを用いた認識の際に、ある特定の方向に間違われていた正面のデータが状態遷移モデルを用いた認識では正面となる例が多く見られた。また、静的特徴量のみを用いた時に比べ、被験者間の F 値の分散も小さくなり、個人依存性は少ないと言える。

6 まとめ

本論文では目の画像パターンから視線認識を行う枠組みにおいて、単一の画像から得られる静的特徴量

だけでなく、複数の画像の差分から得られる動的特徴量も組み合わせて認識を行うことにより認識精度の向上を試みた。静的特徴量と動的特徴量を統合する枠組みとして状態遷移モデルを用いた。

実際の対話から収集したデータで実験を行った結果、静的特徴量のみでの認識で F 値 0.66、状態遷移モデルを用いた認識で F 値 0.89 と精度の向上が確認できた。

一定時間、視線状態を観察することで、より精度の高い認識が行えることが分かった。しかし、今回は実時間による認識は考慮していない。今回の結果を実時間での認識につなげるためには、得られたデータを用いて MLLR 等の適応手法により学習モデルを適応する必要があるが、その時の認識精度を確認する必要がある。

参考文献

- [1] 中野有紀子, 岡 兼司, 佐藤洋一, 西田豊明, “ユーザの視線に気づく会話エージェント - アテンションの知覚と制御を利用した会話の円滑化 -,” The 19th Annual Conference of the Japanese Society for Artificial Intelligence, 3B2-08, 2005.
- [2] I. Matthews and S. Baker, “Active appearance models revisited,” Robotics Institute, Carnegie Mellon University, Pittsburgh, PA, Tech. Rep. CMU-RI-TR-03-02, April 2003.
- [3] J. Zhu and J. Yang, “Subpixel eye gaze tracking,” IEEE. Proc. FGR, 2002.
- [4] T. Ishikawa, S. Baker, I. Matthews, and T. Kanade, “Passive driver gaze tracking with active appearance models,” Proc. 11th World Congress on Intelligent Transportation Systems, Oct. 2004.
- [5] J.G. Wang and E. Sung, “Study on eye gaze estimation,” IEEE. Trans. vol.32, no.3, pp.332-350, June, 2002.
- [6] H. Wu, Q. Chen, and T. Wada, “Visual line estimation from a single image of two eyes,” Proc. IEEE ICPR, vol.3, pp.290-293, Aug. 2004.
- [7] S. Baluja and D. Pomerleau, “Non-intrusive gaze tracking using artificial neural networks,” CMU CS Technical Report, CMU-CS-94-102, Jan. 1994.
- [8] 田中克己, 福井和広, “エージェントによるリアルタイムインタラクションを活用した視線入力インタフェース,” 信学論 (D-II), vol.J85-D-II, no.9, pp.1464-1472, Sep. 2002.
- [9] K. Tan, D.J. Kriegman, N. Ahuja, “Appearance-based Eye Gaze Estimation,” Proc. IEEE WACV, pp.191-195, 2002.
- [10] 小野泰弘, 岡部孝弘, 佐藤洋一, “目領域の切り出しの不定性を考慮した低解像度からの視線方向認識,” 情報処理学会論文誌, vol.47, no.SIG 10(CVIM 15), pp.173-184, July 2006.
- [11] 庄境 誠, 奈木野豪秀, “多次元尺度構成法による音響空間の 2 次元可視化,” 情処学研報, SLP-52, pp.129-136, July 2004.

表 3: 静的特徴量のみを用いた時の評価値 (状態遷移モデルを用いて $\alpha = 1.0$, $\beta = 0.0$, $\gamma = 0.0$ とした場合)

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	平均
recall	0.01	0.38	0.90	0.68	0.53	0.31	0.10	0.91	0.36	0.00	0.31	0.35	0.05	0.78	0.53	0.87	0.44
precision	0.67	0.89	0.98	1.00	0.97	0.92	0.97	0.96	0.52	0.50	1.00	0.76	0.89	0.86	0.83	0.93	0.85
F	0.34	0.64	0.94	0.84	0.75	0.62	0.54	0.94	0.44	0.25	0.66	0.56	0.47	0.82	0.68	0.90	0.68

表 4: 状態遷移モデルを用いた時の正解率 [%] ($\alpha = 0.1$, $\beta = 0.4$, $\gamma = 0.5$)

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	平均
recall	0.81	0.96	0.91	1	0.88	0.95	0.96	0.99	0.9	0.93	0.91	0.82	0.95	0.97	0.94	0.98	0.93
precision	0.82	0.86	0.95	0.99	0.85	0.86	0.81	0.94	0.61	0.97	0.96	0.76	0.86	0.84	0.71	0.93	0.86
F	0.82	0.91	0.93	1.00	0.87	0.91	0.89	0.97	0.76	0.95	0.94	0.79	0.91	0.91	0.83	0.96	0.89

表 5: 状態遷移モデルを用いた認識時の α , β , γ 毎の評価値

		β											
		0.0	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1.0	
α	0.0	recall	1.00	1.00	1.00	0.99	0.95	0.93	0.87	0.83	0.74	0.60	0.27
		precision	0.72	0.72	0.73	0.76	0.80	0.82	0.83	0.85	0.85	0.84	0.77
	0.1	recall	1.00	1.00	0.99	0.97	0.93	0.87	0.79	0.69	0.58	0.49	
		precision	0.73	0.73	0.76	0.82	0.86	0.88	0.89	0.89	0.87	0.86	
	0.2	recall	0.96	0.94	0.89	0.82	0.76	0.69	0.61	0.54	0.49		
		precision	0.75	0.79	0.84	0.87	0.88	0.88	0.87	0.86	0.86		
	0.3	recall	0.83	0.79	0.75	0.68	0.64	0.58	0.52	0.49			
		precision	0.81	0.84	0.88	0.89	0.89	0.87	0.84	0.84			
	0.4	recall	0.71	0.67	0.63	0.60	0.55	0.52	0.49				
		precision	0.84	0.87	0.89	0.88	0.86	0.87	0.85				
	0.5	recall	0.62	0.60	0.56	0.54	0.51	0.48					
		precision	0.80	0.88	0.86	0.84	0.86	0.85					
	0.6	recall	0.57	0.55	0.52	0.50	0.48						
		precision	0.81	0.89	0.87	0.83	0.83						
	0.7	recall	0.54	0.51	0.50	0.47							
		precision	0.85	0.89	0.88	0.85							
	0.8	recall	0.49	0.48	0.46								
		precision	0.86	0.89	0.88								
0.9	recall	0.45	0.45										
	precision	0.89	0.89										
1.0	recall	0.44											
	precision	0.85											