

2. Жарко Е.Ф. Оценка качества программного обеспечения для систем, важных для безопасности АЭС // Информационные технологии и вычислительные системы. – 2011. – № 3. – С. 38-44.

3. ГОСТ Р МЭК 60880-2010. Атомные электростанции. Системы контроля и управления, важные для безопасности. Программное обеспечение компьютерных систем, выполняющих функции категории А. – М.: Стандартинформ, 2011. – 90 с.

4. ГОСТ Р МЭК 62138-2021. Атомные электростанции. Программное обеспечение систем контроля и управления атомной станции, выполняющих функции безопасности категорий В и С. Общие требования. – М.: Российский институт стандартизации, 2022. – 46 с.

5. IEEE Std 1012-2016. IEEE Standard for System, Software, and Hardware Verification and Validation. – IEEE, 2017. – 260 p.

DOI: 10.25728/iccss.2022.22.70.021

Тимиршайхова Ю.В., Шагин Н.А.

Преимущества и недостатки классических методов нахождения лиц

Аннотация. В настоящее время вопросы информационной безопасности стали главной задачей для всего мира. Чтобы решить такую задачу создаются биометрические системы. В статье рассмотрены классические методы нахождения лиц по изображению. Проведен анализ достоинств и недостатков рассмотренных методов. Предлагается постановка задачи исследования выявления лиц по классическим методам.

Ключевые слова: алгоритмы нахождения лиц, метод главных компонент, Eigenfaces, линейный дискриминантный алгоритм, Fisherfaces, метод Виолы-Джонса

Во всех методах распознавания лиц основной задачей является нахождение лица на изображении. Популярные методы нахождения лиц делятся на два основных класса: классические (метод главных компонент, линейный дискриминантный алгоритм, метод Виолы-

Джонса,) и нейросетевые (использование искусственных нейронных сетей).

Работая с изображениями высокого разрешения, приходится сталкиваться со слишком большой размерностью векторного пространства. Если учесть, что, решая задачу распознавания лиц зачастую приходится работать с десятками, а иногда и с сотнями тысяч изображений в различных форматах, то большая размерность исследуемых данных может затруднить целевые вычисления. Данная проблема хорошо решается методом главных компонент (Principal Component Analysis – далее PCA) – один из основных способов уменьшить размерность данных, потеряв наименьшее количество информации.

В 1988 году Майкл Кирби и Лоуренс Сирович применили подход «собственных лиц» (Eigenfaces) с использованием линейной алгебры для анализа изображений [1]. Для разметки лиц они применяли менее 100 различных значений, доказав, что этого достаточно для точного кодирования изображения лица. Через три года технология Eigenfaces была усовершенствована использованием некоторых факторов окружающей среды, что в свою очередь помогло автоматизировать процесс распознавания. Перейдем к рассмотрению классического метода, в основе которого лежит вышеупомянутый PCA.

Математическое описание алгоритма Eigenfaces:

Пусть $X = \{x_1, x_2, \dots, x_n\}$ вектор признаков $x_i \in \mathbb{R}^d$.

1. Вычисление среднего и ковариационной матрицы

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

$$S = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T \quad (2)$$

2. Вычисление собственных чисел λ_i и собственных векторов v_i матрицы S

$$Sv_i = \lambda_i v_i, i = 1, 2, \dots, n \quad (3)$$

3. Упорядочивание собственных векторов по убыванию собственных значений т.е. k главных компонент – собственные векторы, соответствующие k наибольшим собственным значениям.

4. k главных компонент вектора x задаются формулой

$$y = W^T(x - \mu), \quad (4)$$

где $W = (v_1, v_2, \dots, v_3)$.

Исходя из PCA базиса находим

$$x = Wy + \mu \quad (5)$$

Другими словами, метод Eigenfaces выполняет распознавание лиц с помощью:

1) проецирования всей обучающей выборки в подпространство PCA по формуле (4).

2) проецирования целевого изображения в подпространство PCA по формуле (5).

3) поиска ближайшего соседа между проецируемыми изображениями, взятыми для обучения и целевым проецируемым изображением, взятым для распознавания.

На рисунке 1 приведены результаты по построению Eigenfaces на основе изображений из AT&T Facedatabase. Была использована палитра Jet для наглядности распределения значений оттенков серого внутри каждого собственного лица. Исходя из этого рисунка можно видеть, что каждый из Eigenfaces содержит в себе не только характерные признаки лица, но и информацию об освещенности. Это отчетливо видно на левой части #4 и правой части #5 лица.

Таким образом, основное преимущество алгоритма – это наличие возможности хранения и поиска изображения в больших базах данных. Недостатком является его чувствительность к внешним факторам. Если присутствуют значительные изменения в условиях входных данных, то эффективность Eigenfaces падает в связи с тем, что не учитывается классовое разделение, и поэтому при удалении некоторых компонент возможна потеря дискриминантной информации. Метод требует идеальных условий, таких как освещенность, ракурс, отсутствие растительности на лице, маски и

тому подобное. Например, во время пандемии эффективность применения данного метода была низкой, поскольку все ходили в масках, а метод выбирает подпространство так, чтобы предельно приблизить входной набор данных, а не разделять изображения на классы. Это может послужить причиной плохих результатов, в особенности, когда дело доходит до решения задачи классификации. Для решения этой причины используется линейный дискриминантный анализ (от англ. Linear discriminant analysis).




Рисунок 1 – Собственные лица в палитре Jet из AT&T database

Линейный дискриминантный алгоритм был создан в 1936 году Рональдом Фишером [2]. Идея линейного дискриминантного алгоритма в том, что необходимо найти линейную комбинацию признаков наилучшим образом, разделяющих два или более класса объектов или событий. Полученная комбинация используется в качестве линейного классификатора или для сокращения размерности пространства признаков перед последующей классификацией. Найденные линейные комбинации, полученные с помощью линейного дискриминанта Фишера, называют «Фишеровскими лицами» (от англ. Fisherfaces). Вкратце выбирается

проекция пространства изображения на пространство признаков таким образом, чтобы минимизировать внутриклассовое и максимизировать межклассовое расстояние в пространстве признаков. Смысл в том, что одни и те же классы должны плотно группироваться вместе [3, 4].

Математическое описание алгоритма Fisherfaces.

Пусть X – вектор выборок для c классов

$$X = \{X_1, X_2, \dots, X_c\}$$

$$X_i = \{x_1, x_2, \dots, x_n\}$$

Вычисляются следующие матрицы рассеивания

$$S_B = \sum_{i=1}^c N_i (\mu_i - \mu) (\mu_i - \mu)^T \quad (6)$$

$$S_W = \sum_{i=1}^c \sum_{x_j \in X_i} (x_j - \mu_i) (x_j - \mu_i)^T \quad (7)$$

$$\mu_i = \frac{1}{|X_i|} \sum_{x_j \in X_i} x_j - \text{среднее внутри класса, } i \in \{1, \dots, c\} \quad (8)$$

Геометрическая интерпретация матриц S_B и S_W для задачи с тремя классами ($c=3$) приведена на рисунке 2.

Классический алгоритм Фишера ищет проекцию W , которая максимизирует критерий разделения классов

$$W_{opt} = \operatorname{argmax}_W \frac{|W^T S_B W|}{|W^T S_W W|} \quad (9)$$

Решение оптимизационной задачи получается из решения следующего базового уравнения линейной алгебры

$$S_B v_i = \lambda_i S_W v_i \quad (10)$$

$$S_W^{-1} S_B v_i = \lambda_i v_i \quad (11)$$




Рисунок 2 – Матрицы S_B и S_W для задачи с тремя классами ($c=3$)

Поскольку Fisherfaces предполагает наличие множества фотографий при разных условиях освещенности у каждого человека в базе данных, то преимуществом данного метода и является устойчивость к изменениям условиям освещенности (продемонстрировано на рисунке 3).

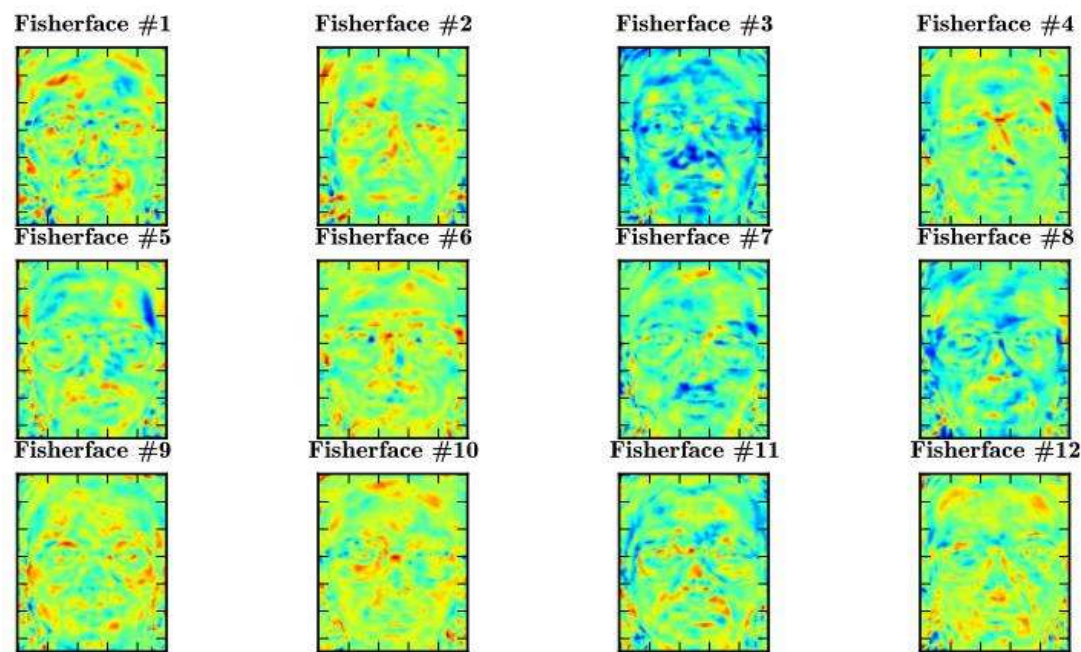


Рисунок 3 – 12 Fisherfaces на основе изображений из AT&T database

Дискриминантный анализ по определению помогает сфокусироваться только на основных лицевых признаках для решения классификационной задачи. Однако стоит отметить, что классический метод также чувствителен к входным данным. Например, если обучать алгоритм на освещенных объектах, а тестировать на слабоосвещенных, то в данном случае с высокой вероятностью метод будет выдавать ошибочные результаты при распознавании лиц.

Метод Виолы-Джонса был разработан Полом Виолой и Майклом Джонсоном в 2001 году. Данный метод получил широкое применение в силу своей скорости и минимальным ложным срабатыванием [5]. Идея алгоритма заключается в выделении локальных признаков изображения. То есть перед началом распознавания алгоритм обучения на базе изображений обучает классификатор, состоящий из значений определённых признаков. Затем алгоритм распознавания ищет объекты на разных масштабах изображения, основываясь на обученном классификаторе. На выходе алгоритма выдаётся большое число обнаруженных объектов на разных масштабах. Алгоритм Виолы-Джонса использует принципы: признаки Хаара; AdaBoost.

Как было описано выше, алгоритм выделяет признаки изображения. Признаки, которые использовали П. Виола и М. Джонсон базируются на каскадах признаков Хаара. Данные признаки использовали, чтобы уйти от пиксельного представления с сохранением скорости вычисления признака. Признаки Хаара представляют собой прямоугольные области, которые составлены из нескольких соседних прямоугольных областей, отмеченных как светлая или темная. Каждый признак способен продемонстрировать наличие или отсутствие того или иного свойства изображения. Например, признак из двух смежных прямоугольных областей способен продемонстрировать в каком месте расположена граница между темным и светлым, легко сможет отразить темнее область глаз и светлее область носа. Наклонные признаки позволяют определить наличие края под углом 45 градусов.

AdaBoost – алгоритм машинного обучения, предложенный Йоавом Фройндом и Робертом Шапиром [5]. AdaBoost во время обучения строит каскад из базовых алгоритмов обучения с целью

улучшить эффективность, то есть каждый следующий алгоритм строится так, чтобы компенсировать недостатки предыдущих.

Преимущества алгоритма в легкости реализации, в наличии навыка к обобщению (алгоритм дополняет точность обучения, превосходя по качеству базовые алгоритмы). Также имеются и недостатки алгоритма: чтобы обучить алгоритм необходимо давать большое количество выборок; алгоритм иногда строит большие каскады из базовых алгоритмов в следствие чего повышается время обучения и затраты на память для хранения каскадов.

Из выше сказанного метод Виолы-Джонса имеет ряд преимуществ такие как: способность распознавать любые объекты, следует только обучить каскад-классификаторов; высокая точность распознавания; подходит для распознавания в реальном времени. Так же, как и у всех алгоритмов у метода Виолы-Джонса имеются недостатки: длительное время на обучение каскадов классификаторов, при угле наклона больше 30° вероятность обнаружения лица резко падает [6].

Заключение

Рассмотренные в статье классические методы нахождения лиц имеют достоинства и недостатки. В дальнейшем планируется рассмотреть популярные архитектуры нейронных сетей, выделить их преимущества и недостатки и определить алгоритмы, которые не имеют приведенные недостатки.

Литература:

1. *Kirby M., Sirovich L.* Application of the Karhunen-Loeve procedure for the characterization of human faces // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 1990. – Vol. 12. № 1. – P. 103-108. DOI: 10.1109/34.41390

2. Линейный дискриминантный анализ. – URL: https://ru.wikipedia.org/wiki/Линейный_дискриминантный_анализ (дата обращения 08.08.2022).

3. *Левчук С.А., Якименко А.А.* Исследование характеристик алгоритмов распознавания лиц // Сборник научных трудов НГТУ. – 2018. – № 3-4 (93). – С. 40-58.

4. *Исаев А.Л., Газаров Д.А., Евсеев С.Д.* Распознавание лиц по изображениям // Символ науки: международный научный журнал. – 2017. – Т. 2. № 4. – С. 70-76.

5. *Тымчук А.И.* Метод Виолы-Джонса для распознавания объектов на изображении // Современная наука: актуальные проблемы теории и практики. Серия: Естественные и технические науки. – 2017. – №6. – С. 63-68.

6. *Мищенко Е.С.* Сравнительный анализ алгоритмов распознавания лиц // Вестник Волгоградского государственного университета. Серия 9. Исследования молодых ученых. – 2013. – № 11. – С. 74-76.

DOI: 10.25728/iccsm.2022.52.62.022

Козлов А.Д., Нога Н.Л.

Метод усредненных коэффициентов влияния для формирования нечеткой базы знаний при оценке рисков информационной безопасности

Аннотация: Предложен метод, позволяющий сократить трудозатраты для формирования продукционных правил (нечеткой базы знаний) при определении рисков информационной безопасности с использованием методов нечеткой логики.

Ключевые слова: риски, информационная безопасность, нечеткая логика, продукционные правила, коэффициенты влияния

Широкое внедрение цифровизации в экономику связано с появлением новых вызовов и угроз. Особенно важно учитывать эти вызовы и угрозы в условиях жестких санкций. При эксплуатации информационных систем, особенно КИИ, требуется постоянно мониторить и оценивать риск информационной и кибербезопасности.

Принципы руководства и технологии обеспечения менеджмента риска определены нормативными документами [1, 2].

Методов оценки риска существует достаточно много. Все они имеют свои плюсы и минусы. У большинства из них присутствует существенный недостаток – они плохо работают в условиях неопределенности. В работе [3] предложена методика оценки риска с использованием методов нечеткой логики. Данная методика